

SVEUČILIŠTE U ZAGREBU
FAKULTET STROJARSTVA I BRODOGRADNJE

DIPLOMSKI RAD

Matija Pečet

Zagreb, 2018.

SVEUČILIŠTE U ZAGREBU
FAKULTET STROJARSTVA I BRODOGRADNJE

DIPLOMSKI RAD

Mentor:

Prof. dr. sc. Zoran Lulić, dipl. ing. stroj.

Student:

Matija Pečet

Zagreb, 2018.

Izjavljujem da sam ovaj rad izradio samostalno koristeći znanja stečena tijekom studija i navedenu literaturu.

Najsrdajnije se zahvaljujem voditelju rada prof. dr. sc. Zoranu Luliću na ukazanom povjerenju, nesebičnom odvajanju vremena i mnogim sugestijama tijekom vođenja ovog rada koje su značajno pridonijele njegovoj kvaliteti te velikoj motivaciji pruženoj kroz zajednički rad tijekom cijelog diplomskog i preddiplomskog studija.

Zahvaljujem se doc. dr. sc. Luki Novačku s Fakulteta prometnih znanosti, Sveučilišta u Zagrebu na savjetima i uloženom vremenu kako bih naučio osnove modeliranja prometa.

Na kraju, posebno se zahvaljujem svojim roditeljima, Oliveri i Ivanu, na pruženoj podršci i pomoći bez koje ne bih uspješno završio studij.

Matija Pečet



SVEUČILIŠTE U ZAGREBU
FAKULTET STROJARSTVA I BRODOGRADNJE



Središnje povjerenstvo za završne i diplomske ispite
Povjerenstvo za diplomske ispite studija strojarstva za smjerove:
procesno-energetski, konstrukcijski, broдостrojarski i inženjersko modeliranje i računalne simulacije

Sveučilište u Zagrebu Fakultet strojarstva i brodogradnje	
Datum	Prilog
Klasa:	
Ur. broj:	

DIPLOMSKI ZADATAK

Student: **Matija Pečet**

Mat. br.: 0035195277

Naslov rada na hrvatskom jeziku: **Model prometa i procjena emisija iz cestovnog prometa u gradu Ozlju**

Naslov rada na engleskom jeziku: **Road Traffic Model and Emission Assessment for the City of Ozalj**

Opis zadatka:

Za razliku od većine sektora (industrija, zgradarstvo, proizvodnja energije itd.) u kojima se bilježi trend smanjenja potrošnje energije i emisija, u sektoru cestovnog prometa trend je suprotan. Procjenjuje se da cestovni promet u Republici Hrvatskoj, kao i u Europi, doprinosi ukupnim emisijama CO₂ s približno 30 %, dok je za neke od štetnih tvari kao što su čestice taj doprinos i do 60 %.

Primjenom različitih mjera, nastoji se smanjiti emisije, a prije uvođenja pojedine mjere potrebno je procijeniti njen potencijalni učinak na buduće emisije, odnosno na njihovo smanjenje.

Procjena učinka pojedine mjere može se provesti izradom modela prometa, na kojem se putem različitih scenarija provode simulacije s ciljem stjecanja uvida u učinak pojedine mjere.

Modeli prometa se izrađuju za različite veličine područja obuhvata od pojedinačne prometnice, nekoliko prometnica, preko gradskih kvartova pa sve do modela prometa na razini države. Za njihovu izradu ključni su podaci o geokoordinatama prometnica, tijeku prometa i strukturi vozila koja njima prometuju. Budući da s veličinom modela raste kompleksnost i broj podataka, izrada modela prometa predstavlja jedno od glavnih ograničenja pri procjeni emisija iz prometa.

Kako za grad Ozalj postoje dostupni podaci o prometu, u okviru diplomskog rada te podatke treba iskoristiti za izradu četverostupanjskog modela prometa cestovnih vozila.

U okviru diplomskog rada potrebno je:

- dati pregled trenutno korištenih metoda izračuna emisija iz cestovnog prometa motornih vozila;
- osmisлити nekoliko scenarija mogućih prometnih tokova u gradu Ozlju te ih analizirati i potom međusobno usporediti u prikladnom programskom okruženju;
- za odabrane scenarije prometa na prometnicama grada Ozlja pomoću programa „COPERT: Street level“ procijeniti emisije;
- osmisлити načine prikaza podataka s procjenom emisija po pojedinim prometnicama. Po mogućnosti za prikaz podataka koristiti neki od javno dostupnih GIS programa (QGIS, ArcGIS).

U radu je potrebno navesti korištenu literaturu i eventualno dobivenu pomoć.

Zadatak zadan:

Datum predaje rada:

Predviđeni datum obrane:

27. rujna 2018.

29. studenog 2018.

5., 6. i 7. prosinca 2018.

Zadatak zadao:

Predsjednica Povjerenstva:

Prof. dr. sc. Zoran Lulić

Prof. dr. sc. Tanja Jurčević Lulić

SADRŽAJ

SADRŽAJ.....	I
POPIS SLIKA.....	III
POPIS TABLICA.....	VI
POPIS OZNAKA	VII
POPIS KRATICA	VII
SAŽETAK	VIII
SUMMARY.....	IX
1. UVOD	1
1.1. Struktura rada.....	4
2. OPĆI PODACI I PROMETNE ZNAČAJKE GRADA OZLJA	5
3. KLASIČNI ČETVEROSTUPANJSKI MODEL PROMETNE POTRAŽNJE.....	7
3.1. Prikupljanje ulaznih podataka	8
3.1.1. Metode prikupljanja podataka	8
3.1.1.1. Anketiranje kućanstava.....	9
3.1.1.2. Anketiranje vozača	10
3.2. Definiranje parametara prijevozne ponude	12
3.2.1. Zoniranje	12
3.2.2. Prometna mreža	13
3.2.3. Prijevozni sustavi	16
3.3. Podmodel generiranja putovanja.....	16
3.3.1. Regresijska analiza	17
3.3.2. Kategorijska analiza.....	21
3.3.3. Usklađivanje produkcije i atrakcije putovanja	22
3.4. Podmodel distribucije putovanja.....	22
3.4.1. Generalizirani trošak putovanja	24
3.4.2. Gravitacijski model	24
3.4.3. Modeli faktora porasta	28
3.5. Podmodel modalne raspodjele putovanja.....	28
3.5.1. Diskretni model odabira	29
3.5.1.1. Binarni Logit model	29
3.5.1.2. Multinomijalni Logit model	30
3.6. Podmodel asignacije putovanja na prometnu mrežu	31
3.6.1. Metode dodjeljivanja putovanja na mrežu.....	32
3.6.1.1. Metoda dodjeljivanja putovanja „sve ili ništa“	32
3.6.1.2. Stohastička metoda dodjeljivanja putovanja.....	33
3.6.1.3. Ekvilibrijalna metoda dodjeljivanja putovanja.....	33

3.6.1.4. Dinamička metoda dodjeljivanja putovanja	36
4. STRUKTURA VOZNOG PARKA	37
4.1. Struktura voznog parka po kategorijama vozila	37
4.2. Passenger Car Units	37
4.3. Struktura vozila prema pogonskom gorivu	38
4.4. Struktura vozila po <i>Euro</i> emisijskim razredima	38
5. MODEL PROMETA U PROGRAMU <i>PTV VISUM</i>	41
5.1. Izrada modela prometa (sadašnje stanje, Case 0.X)	42
5.2. Definicija različitih scenarija razvoja prometa	55
5.2.1. Scenarij 1 – gradnja novog mosta (1.X)	56
5.2.2. Scenarij 2 – uvođenje linije javnog gradskog prijevoza (2.X)	58
5.2.3. Scenarij 3 – upravljanje u incidentnim situacijama	60
5.3. Raspodjela putovanja kroz dan	62
6. IZRAČUN EMISIJA IZ CESTOVNOG PROMETA U PROGRAMU <i>COPERT</i> : <i>STREET LEVEL</i>	63
6.1. O emisijama iz cestovnog prometa	63
6.2. Izračun emisija iz cestovnog prometa	64
6.3. Primjer izračuna emisija u programu <i>COPERT: Street Level</i>	67
6.4. Scenariji izračuna emisija iz cestovnog prometa	73
6.4.1. Sadašnje stanje voznog parka (X.0)	74
6.4.2. Scenarij 1 (X.1)	75
6.4.3. Scenarij 2 (X.2)	76
6.4.4. Prikaz rezultata za sve scenarije	76
6.4.5. Izračun emisija za radni dan	78
7. PRIKAZ EMISIJA NA KARTI U PROGRAMU <i>QGIS</i>	79
7.1. Izrada karte u <i>QGIS</i> – u	79
8. ZAKLJUČAK	85
LITERATURA	89
PRILOG	92

POPIS SLIKA

Slika 1. Razine prometnog modeliranja [3].....	2
Slika 2. Grad Ozalj na zemljovidu Hrvatske [11, 12].....	6
Slika 3. Prometnice u Ozlju	6
Slika 4. Klasični četverostupanjski model prometne potražnje	7
Slika 5. Primjer anketnog lista	11
Slika 6. Prometne zone regije Hauge – Rotterdam u Nizozemskoj [1].....	12
Slika 7. Osnovni elementi prometne mreže [1]	14
Slika 8. Produkcija i atrakcija putovanja prema izvorištu i odredištu [1]	17
Slika 9. Pravac regresije i koeficijent determinacije	18
Slika 10. Faktori generiranja putovanja za kuću [14]	19
Slika 11. Faktor generiranja putovanja za stan [14]	20
Slika 12. Grad podijeljen na zone	26
Slika 13. Moguće rute putovanja.....	34
Slika 14. Kod u MATLABU	36
Slika 15. Rješenja primjera 5. u MATLABU	36
Slika 16. Osnovna (default) struktura voznog parka po kategorijama vozila u CSL ..	37
Slika 17. Struktura putničkih automobila po pogonskom gorivu.....	38
Slika 18. Struktura automobila (M1 i N1) pogonjenih benzinom, dizelskim gorivom i LPG - om prema Euro emisijskim razredima za grad Ozalj (2017. godina)	39
Slika 19. Struktura automobila (M1 i N1) pogonjenih benzinom, dizelskim gorivom i LPG - om prema Euro emisijskim razredima (Republika Hrvatska, 2016. godina)	40
Slika 20. Logo i ikona programa PTV VISUM [19]	41
Slika 21. Ikona Nodes u izborniku Network	42
Slika 22. Ikona Links u izborniku Network.....	42
Slika 23. Ikona Zones u izborniku Network (lijevo) i atributi zone (desno).....	42
Slika 24. Ikona Connectors u izborniku Network	42
Slika 25. Raskrižja i krajnji čvorovi (1.).....	43
Slika 26. Linkovi i legenda (2.).....	44
Slika 27. Zone (3.)	45
Slika 28. Konektori (4.).....	46
Slika 29. Dodavanje Initial Assignmenta u proceduru.....	47
Slika 30. Koraci procedure nakon dodavanja Initial assignmenta	47
Slika 31. Dodavanje Trip generation u proceduru	48
Slika 32. Koraci procedure nakon dodavanja Trip generationa	48
Slika 33. Funkcije produkcije i atrakcije	48
Slika 34. Dodavanje Calculate PrT skim matrix u proceduru.....	49
Slika 35. Koraci procedure nakon dodavanja Calculate PrT skim matrix	49
Slika 36. Dodavanje Trip distributiona u proceduru	50
Slika 37. Parametri kombinirane (Tannerove) funkcije	50

Slika 38. Koraci procedure nakon dodavanja Trip distributiona	50
Slika 39. Dodavanje Mode choichea u proceduru	51
Slika 40. Koraci procedure nakon dodavanja Mode choichea	51
Slika 41. Dodavanje PrT assigmenta u proceduru.....	52
Slika 42. Koraci procedure nakon dodavanja PrT assigmenta	52
Slika 43. Svi koraci procedure uspješno izvedeni.....	52
Slika 44. Broj putovanja za sadašnje stanje razvoja prometa za jutarnji vršni sat radnim danom	53
Slika 45. Broj putovanja u centru grada za sadašnje stanje razvoja prometa za jutarnji vršni sat radnim danom	54
Slika 46. Lista linkova s atributima	54
Slika 47. Most u Ozlju [9].....	56
Slika 48. Broj putovanja u centru grada nakon izgradnje novog mosta za jutarnji vršni sat radnim danom	56
Slika 49. Broj putovanja nakon izgradnje novog mosta za jutarnji vršni sat radnim danom.....	57
Slika 50. Trasa autobusne linije	58
Slika 51. Predviđeni vozni red autobusne linije radnim danom	58
Slika 52. Procedura za izračun putovanja nakon dodavanja autobusne linije	59
Slika 53. Funkcije binarnog Logit modela.....	59
Slika 54. Svi koraci procedure uspješno izvedeni.....	59
Slika 55. Broj putovanja nakon uvođenja linija javnog prijevoza za jutarnji vršni sat radnim danom	60
Slika 56. Broj putovanja u centru tijekom incidentne situacije	60
Slika 57. Ukupan broj putovanja u Ozlju tijekom incidentne situacije	61
Slika 58. Raspodjela putovanja u ulaznim zonama radnim danom	62
Slika 59. Raspodjela putovanja u izlaznim zonama radnim danom.....	62
Slika 60. Logo i ikona programa COPERT: Street Levela [27]	64
Slika 61. Emisijski faktori za osobna vozila pogonjena benzinom	65
Slika 62. Emisijski faktori za osobna vozila pogonjena dizelskim gorivom	65
Slika 63. Excel datoteka s ulaznim podacima.....	67
Slika 64. Dijaloški okvir za popunjavanje ulaznih podataka u COPERT: Street Level.....	67
Slika 65. Predložene PCU vrijednosti	68
Slika 66. Ponuđena (default) struktura voznog parka	68
Slika 67. Struktura osobnih vozila prema pogonskom gorivu	69
Slika 68. Struktura vozila pogonjenih benzinom i dizelskim gorivom prema Euro emisijskim razredima.....	70
Slika 69. Pokretanje izračuna	71
Slika 70. Izbornih Results	71
Slika 71. Prikaz rezultata By Row	71
Slika 72. Prikaz rezultata On Map za CO ₂ i NO _x	72
Slika 73. Izračun broja vozila na prometnici	73

Slika 74. Izbornik za određivanje ulaznih pataka u programu COPERT: Street Level	74
Slika 75. Sadašnja struktura vozila (lijevo) i struktura vozila za Scenarij 1 (desno) prema Euro emisijskim razredima	75
Slika 76. Sadašnja struktura vozila (lijevo) i struktura vozila za Scenarij 2 (desno) prema pogonskom gorivu	76
Slika 77. Emisija CO ₂ radnim danom	78
Slika 78. Logo i ikona programa QGIS [31]	79
Slika 79. Podloga učitana iz Google Mapsa	79
Slika 80. Podloga koja se koristi za izradu karte (OpenStreetMap)	79
Slika 81. Ikona New Shapefile Layera	80
Slika 82. Popunjeni izbornik New Shapefile Layer	80
Slika 83: Postupak za crtanje linije na karti	81
Slika 84. Atributi prometnica	81
Slika 85. Dijaloški okvir Layer Properties	82
Slika 86. Emisija CO ₂ za odabrani primjer u QGIS - u	83
Slika 87. Emisija CO ₂ po prometnicama u Ozlju	84
Slika 88. Dijagram toka procjene emisija tvari iz cestovnog prometa	87

POPIS TABLICA

Tablica 1. Klasifikacija prometnica [1]	15
Tablica 2. Ulazni podaci	17
Tablica 3. Faktori generiranja putovanja.....	21
Tablica 4. Prikaz općeg oblika OD matrice	23
Tablica 5. Podaci o produkciji i atrakciji zona	26
Tablica 6. Vremena putovanja između zona	26
Tablica 7. Generalizirani trošak putovanja između zona	27
Tablica 8. OD matrica za promatrani grad nakon prve iteracije.....	27
Tablica 9. Konačna OD matrica za promatrani grad	27
Tablica 10. Značajke modova prijevoza	30
Tablica 11. Predložene PCU vrijednosti za pojedine kategorije vozila	37
Tablica 12. Broj vozila prema pogonskom gorivu	38
Tablica 13. Broj automobila (M1 i N1) prema Euro emisijskim razredima za grad Ozalj.....	39
Tablica 14. Ulazni podaci za primjer 6.	66
Tablica 15. Matrica scenarija	74
Tablica 16. Usporedba dopuštenih emisijskih razreda za Case X.0 i Scenarij X.1	75
Tablica 17. Emisija CO ₂ , kg.....	77
Tablica 18. Emisija CO, g.....	77
Tablica 19. Emisija NO _x , g.....	77
Tablica 20. Emisija PM, g.....	77
Tablica 21. Emisija VOC, g	77
Tablica 22. Troškovi za emisije u cestovnom prometu	78
Tablica 23. Dnevne emisije radnim danom	78

POPIS OZNAKA

Oznaka	Mjerna jedinica	Opis
a, b, c	-	Parametri Tannerove funkcije
c_{ij}	-	Generalizirani trošak putovanja
D_j	putovanja	Atrakcija putovanja u zoni „j“
D_{UST}	€	Dnevna ušteda ostvarena smanjenjem emisija
d_{ij}	km	Udaljenost između zona „i“ i „j“
E	g, kg	Emisija polutanta
n	-	Broj vozila
O_i	putovanja	Produkcija putovanja zone „i“
P_i	stanovnika	Populacija zone „i“
P_n	-	Vjerojatnost prijevoza modom n
q	voz/h	Protok vozila
R^2	-	Koeficijent determinacije
s	km	Put
T	putovanja	Ukupan broj putovanja
T_{ij}	putovanja	Ukupan broj putovanja između zona „i“ i „j“
V_{in}	-	Korisnost moda prijevoza
α	-	Kalibracijska konstanta
μ	-	Kalibracijska konstanta Logit modela

POPIS KRATICA

Kratika	Opis
CVH	Centar za vozila Hrvatske
EEA	European Environment Agency
EU	Europska Unija
HAK	Hrvatski autoklub
ITE	Institute of Transportation Engineers
ppm	parts per milion

SAŽETAK

U okviru diplomskog rada izrađen je model prometa grada Ozlja. Model prometa pojednostavljeni je prikaz stvarnog stanja prometne mreže, a namijenjen je za istraživanje i procjenu emisija iz cestovnog prometa u gradu Ozlju. Prednost ovakvog načina izračuna je izvodljivost u svim mogućim slučajevima odvijanja prometa. Nakon stvaranja inicijalnog modela i procedure izračuna, jednostavnim korekcijama prometne mreže može se provesti „što ako“ (engl. „*what if*“) analizu raznih scenarija razvoja prometnih tokova. Istraživanje se može podijeliti na dvije velike cjeline: izrada prometnog modela i procjena emisija iz cestovnog prometa.

U prvom dijelu rada, za izradu prometnog modela prometa upotrijebljen je klasični četverostupanjski model prometa razvijen 60 – ih godina prošlog stoljeća, a vrlo često se koristi i danas. Model se izrađuje kroz četiri koraka: generiranje putovanja, distribucija putovanja, modalna raspodjela putovanja i dodjeljivanje putovanja na mrežu.

U uvodnom dijelu izrade modela prometa prikazane su teorijske osnove četverostupanjskog modela i za svaki korak dan je numerički primjer radi lakšeg razumijevanja postupaka koje program provodi. Nakon svladavanja teorijskih osnova, u programu *PTV Visum* je izrađen prometni model i razmatrano je nekoliko scenarija odvijanja prometa koji prikazuju mogućnosti programa.

U drugom dijelu rada opisan je postupak izračuna emisija iz cestovnog prometa pomoću programa *COPERT: Street Level*, pri čemu je, korištenjem podataka o broju vozila na prometnici, brzinama kretanja vozila, trajanja perioda promatranja i emisijskih faktora, stvorena procjena ukupnih emisija na svim segmentima prometnica. Provedena je procjena emisija za nekolicinu različitih scenarija struktura voznog parka u skladu s trendom porasta broja električnih vozila i „eko - zona“. Rezultati simulacija prometnih tokova i procjena emisija pokazuju da smanjenju emisija najviše pogoduju gradnja novog mosta i modernizacija voznog parka uvođenjem vozila s višim emisijskim razredima.

Ključne riječi: model prometa, četverostupanjski model prometne potražnje, emisije iz cestovnog prometa

SUMMARY

This master's thesis researched a number of traffic models for the city of Ozalj. A traffic model is a simplified overview of real conditions on a traffic network. This study's objective was an estimation of road traffic emissions in the city of Ozalj. The used method of estimation is feasible for any given traffic scenario. After completion of an initial model and calculation procedures, a „what if“ analysis of different traffic scenarios has been conducted by means of simple corrections on a traffic network. The study consists of two large units: traffic model creation and road traffic emissions estimation.

In the first unit, a classic, four step model first developed in the 1960's was utilized to create a traffic flow model. It consists of four steps: trip generation, trip distribution, modal split, and route assignment. In the introduction to model creation, the theoretical bases of the four step model were explained along with the appropriation of numerical examples to each step for a better understanding of program procedures. Following the explanation of these theoretical bases, a traffic model was created in PTV Visum and several traffic flow scenarios were reviewed in order to present program features.

In the second unit, estimations of road traffic emissions were calculated by implementing data pertaining to the number of road vehicles, vehicle velocities, duration of observation periods and emissions factors into *COPERT: Street Level*, for an estimation of total emissions on all road segments. Several different motorpool scenarios were considered, with the growing trends of electrical vehicles and „eco-zones“ in mind. Results of traffic flow simulations and emissions estimations imply that the optimal solution to reducing emissions includes construction of a new bridge as well as raising the share of vehicles with higher emission performance standards by means of motorpool modernization.

Keywords: traffic model, four step traffic model, road traffic emissions

1. UVOD

Prijevoz ljudi i roba s jednog mjesta na drugo obavlja se korištenjem prijevoznih sredstava kao što su: brodovi, vlakovi, automobili, bicikli itd. Prijevozna sredstava, prijevozne usluge i infrastrukturni objekti za vozila u kretanju i mirovanju (cestovne prometnice, željezničke pruge, biciklističke staze, parkirališta i dr.) s organizacijskom (vozni redovi) i upravljačkom opremom (prometna signalizacija) zajedno čine prijevozni (prometni) sustav. [1]

S porastom stanovništva i gospodarskim rastom dolazi do povećane prometne potražnje koja najčešće (ali ne i nužno) vodi do zagušenja prometnica, povećanog onečišćenja okoliša i smanjene sigurnosti odvijanja cestovnog prometa. Raznim kampanjama nastoji se korisnike prometnih sustava poticati na putovanja u različitim vremenima i različitim rutama koje su možda manje zagušene. No za sve te mjere potrebno je znati kako izgleda trenutni prometni tok na promatranom području, odnosno gdje i kada će doći do zagušenja (uska grla). Zato se koriste modeli prometa pomoću kojih je moguće predvidjeti nastanak zagušenja i utjecaj zagušenja na cijelu mrežu. [2]

Model prometa je pojednostavljeni prikaz stvarnog stanja prometa koji daje uvid u kompleksne odnose stvarnih pojava. Na temelju modela mogu se donositi zaključci što bi se moglo dogoditi i kako bi izgledala prometna mreža ako nastupe promjene u uvjetima odvijanja prometa. [1]

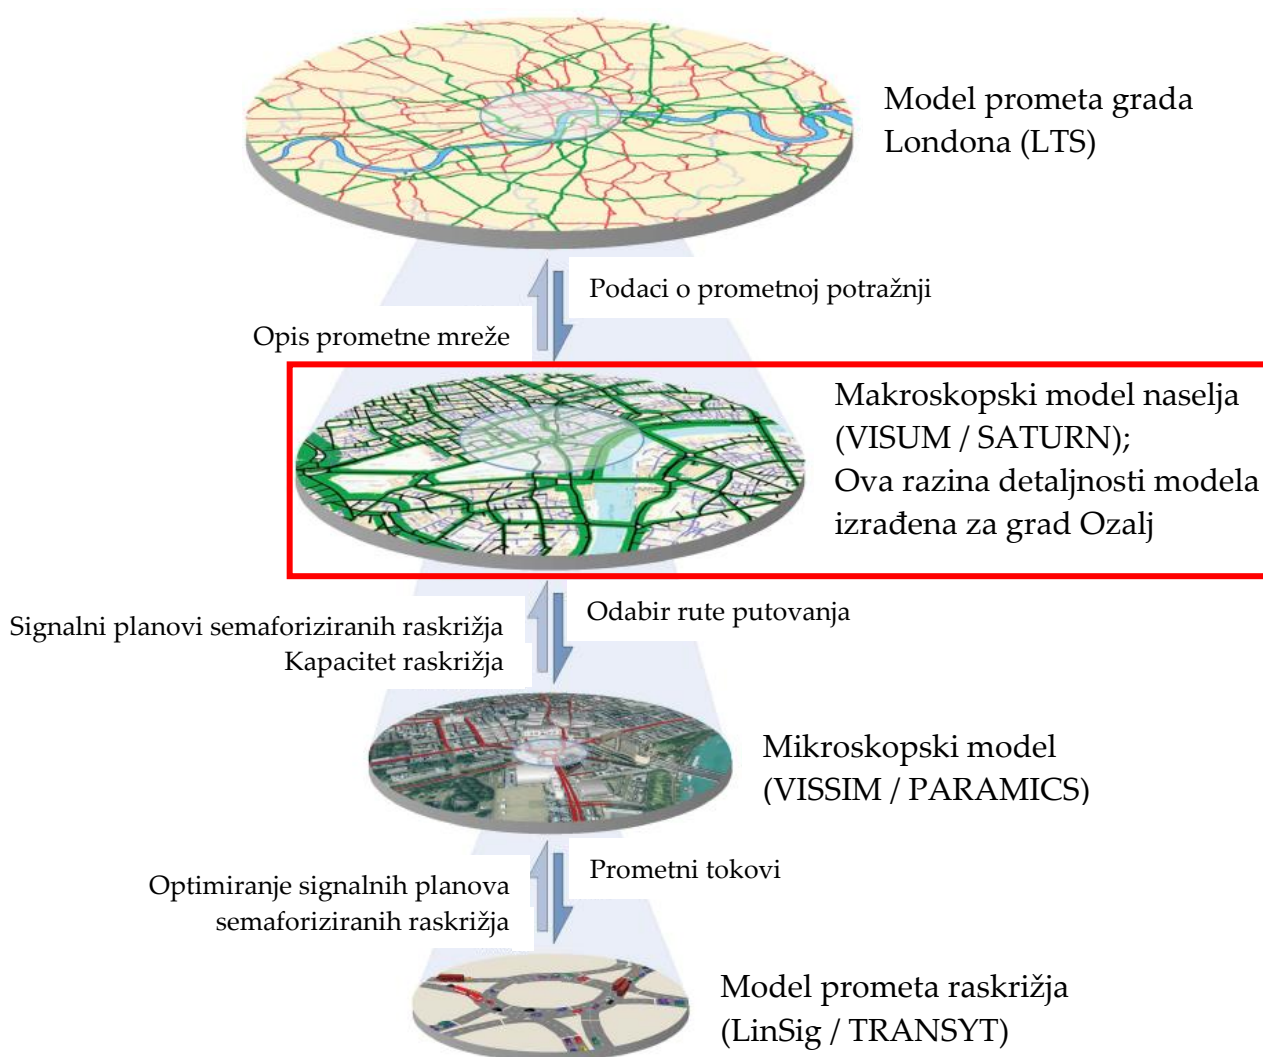
S obzirom na kompleksnost mnogih transportnih problema i velik broj mogućih rješenja samo modeliranjem se mogu procijeniti utjecaji predloženih rješenja na prometni sustav u cjelini. Kako bi se odabralo prikladno rješenje u prometnom planiranju pomoću prometnog modeliranja provjerava se niz varijantnih rješenja kako bi se odabralo optimalno. U slučaju planiranja objekata cestovne infrastrukture predlaže se analiza sljedeće tri varijante:

- Utjecaj na okoliš – rješavanje problema s najmanjim utjecajem na okoliš, što je tema ovog rada;
- Javni gradski prijevoz – poboljšanje prometne ponude javnog gradskog prijevoza (npr. uvođenje nove linije javnog gradskog prijevoza);
- Izgradnja novih građevinskih elemenata prometne ponude (npr. novi most).

Kako bi se mogle uspoređivati varijante predloženih rješenja potrebno je prvo postaviti model postojećeg stanja, a nakon toga model prognozirano stanja. [1]

S obzirom na razinu detaljnosti modeli prometa mogu se podijeliti na:

- Mikroskopski modeli predstavljaju kretanje pojedinačnog vozila unutar nekog manjeg područja (npr. raskrižje). Kretanje svakog pojedinačnog vozila u zadanom vremenskom intervalu funkcija je tehničkih karakteristika vozila, osnovnih zakona gibanja i ponašanja vozača;
- Makroskopski modeli simuliraju prometne tokove uzimajući u obzir osnovne parametre prometnog toka (brzina prometnog toka, protok vozila, gustoća prometnog toka). Ne koriste se za analizu kretanja pojedinačnog vozila već ukupnog prometnog opterećenja prometnica prometne mreže, u ovom slučaju grad Ozalj (crveno označeno na slici 1.);
- Mezoskopski modeli spajaju značajke mikroskopskih i makroskopskih modela, simuliraju ponašanje pojedinačnih vozila (značajke mikroskopskih modela), ali i njihovo kretanje i interakciju na temelju makroskopskih odnosa. [1]



Slika 1. Razine prometnog modeliranja [3]

Vodeće države na svijetu po broju registriranih automobila su Sjedinjene Američke Države s preko 250 milijuna i Narodna Republika Kina s oko 80 milijuna automobila [4]. Za putovanja na ili s posla i za obavljanje posla za poslodavca prevladava osobni automobil s 56 % putovanja na posao i 66 % putovanja radi obavljanja posla za poslodavca. Prosječna osoba u Europi i Sjedinjenim Američkim Državama dnevno provede otprilike jedan sat vremena u vožnji [5, 6]. S druge strane, javni prijevoz je najvažniji oblik putovanja za potrebe obrazovanja s gotovo 90 % svih putovanja [7].

Izgaranjem fosilnih goriva u motorima cestovnih vozila nastaju ispušni plinovi koji sadrže preko stotinu različitih spojeva štetnih za okoliš i ljudsko zdravlje. Homologacijskim propisima Europske Unije određene su dopuštene granice emisija štetnih tvari i metode ispitivanja sljedećih štetnih sastojaka: ugljikovog monoksida (CO), neizgorjelih ugljikovodika (HC) i dušikovih oksida (NO_x). Kod motora s kompresijskim paljenjem (Dieselovi motori) dodatno je ograničena i količina krutih čestica PM (engl. *Particulate Matter*; najveći dio njih čini čađa), neprozirnost ispušnih (u Republici Hrvatskoj se provjerava na redovitom tehničkom pregledu) plinova i nemetanski ugljikovodici (NMHC). Kod vozila na pogon stlačenim prirodnim plinom ograničena je i količina metana (CH_4) u ispušnim plinovima. Također je ograničena i količina hlapljivih tvari koje vozilo ispušta u okoliš iz spremnika i sustava za gorivo. Općenito, smanjivanje emisija štetnih tvari provodi se kontinuiranim poboljšanjima procesa izgaranja u cilindru motora, pročišćavanjem ispušnih plinova nakon što izađu iz motora, poboljšavanjem kvalitete goriva, smanjivanjem otpora vožnje i optimiranjem upravljanja radom motora i vozila u cjelini [8].

1.1. Struktura rada

U drugom poglavlju rada dani su opći podaci o Ozlju i njegovom prometnom smještaju u prometom sustavu Republike Hrvatske i Europske Unije.

U trećem poglavlju prikazana je izrada klasičnog četverostupanjskog prometnog modela. Za svaki korak prikazana je teorijska osnova i numerički primjer kako bi se teorijska podloga bolje razjasnila i dobio uvid u korake koje simulacijski program izvodi.

U četvrtom poglavlju prikazan je struktura voznog parka prema pogonskom gorivu i *Euro* emisijskim razredima. U petom poglavlju opisana je izrada modela u programu *PTV Visum*. Nakon stvaranja inicijalnog modela, napravljena su tri scenarija kako bi se prikazale mogućnosti programa, prikazani su rezultati za svaki scenarij i kratak osvrt na njih.

U šestom poglavlju opisan je način izračuna emisija iz cestovnog prometa i koraci izračuna emisija u programu *COPERT: Street Level*. Dan je numerički primjer izračuna emisija analogan postupku koji provodi program, kako bi se razumio postupak računanja pomoću programu. Nakon izračuna emisija za sadašnje stanje modela prometa i voznog parka, pretpostavljena su tri scenarija i za njih izračunate emisije. Nakon provedenih izračuna i usporedbe emisija odabran su scenariji za koji je smanjenje emisija najveće i dodatno je analiziran.

U sedmom poglavlju izrađena je karta emisijskih faktora za prometnice u programu za prikaz georeferenciranih podataka *QGIS*.

Zaključak s osvrtom na rezultate simulacija prometa i izračuna emisija iz cestovnog prometa, s prijedlozima za poboljšanja su u osmom poglavlju.

2. OPĆI PODACI I PROMETNE ZNAČAJKE GRADA OZLJA

Kao područje studije odabran je grad Ozalj koji se nalazi se u sjeverozapadnom dijelu Karlovačke županije, zauzima površinu od 179,4 km² (slika 2.) na kojoj su smještena mnoga sela i zaselci s ukupno 6 837 stanovnika prema popisu stanovništva iz 2011. godine, a nalazi se na 166 m apsolutne visine. [9]

Ozaljsko područje smješteno je uz donji tok Kupe i njene desne pritoke Dobre, odlikuje se zanimljivom geografskom raznolikošću žumberačkih planina, brežuljaka vrhovačkog vinogorja, široke i plodne pokupske ravnice te ribom bogatih devet jezera Šljunčare. Od Karlovca je udaljen 18 km, 50 km od Zagreba i 120 km od Rijeke. Najpoznatiji spomenik je Stari grad Ozalj. [9]


Područje grada nije prometno izolirano u prostoru Republike Hrvatske. Nalazi se u pograničnom području nedaleko glavnih prometnih tokova, na rubu Karlovačke županije i Središnje Hrvatske. Područje Grada povezuje se s Belom Krajinom u Republici Sloveniji i Bosanskom krajinom u Bosni i Hercegovini u važnom prometnom čvorištu grada Karlovca. Na području Ozlja prevladavaju cestovne prometnice regionalno – županijskog i lokalnog značenja koje služe u međusobnom povezivanju pojedinih njegovih dijelova s neposrednim okolnim prostorima. [9]

Područje Grada Ozlja nalazi se na krajnjem sjeveru Karlovačke županije (slika 2.), unutar koje na zapadu graniči s općinama Žakanje i Ribnik, na jugozapadu s općinom Netretić i na jugoistoku s Gradom Karlovcem. Na sjeveroistoku s općinama Žumberak i Krašić te s Gradom Jastrebarsko iz Zagrebačke županije. Na krajnjem sjeveru i sjeverozapadu s Republikom Slovenijom, po čemu ima značenje pograničnog područja. U ovom području nalaze se međunarodni granični prijelazi Jurovski brod (D228) na međunarodnoj magistralnoj cesti Karlovac – Metlika, državni granični prijelaz Krmačina na regionalnoj cesti Krašić – Vidovina – Metlika te pogranični prijelazi Brašljeвица, Ostriž, Liješće i Brezovica Žumberačka na lokalnim cestama u području Žumberka. [9] Prometnice u Ozlju prikazane su na slici 3.

Grad se prvi put spominje 1244. kao slobodni kraljevski grad. Od kraja 14. stoljeća je u vlasništvu Frankopana iz čijih ruku je rodbinskim vezama 1550. prešao pod obitelj Zrinski, koja ostaje vlasnik sve do 1671. Najpoznatija znamenitost je srednjovjekovni grad Ozalj leži na klisuri, na lijevoj obali Kupe, a oklopljen je čvrstim zidinama s obrambenim kulama i pokretnim mostom. Zbog mnogih pregradnji sačuvan je tek manji dio starijeg kompleksa. U gradu je smješten Zavičajni muzej i crkva svetog Vida s grobom posljednjega hrvatskog bana Nikole Tomašića. Novi dio grada znatnije se počeo razvijati početkom 20. stoljeća, kada su izgrađene željeznica (1913.) i hidroelektrana Ozalj I (1908.) [10].



Slika 2. Grad Ozalj na zemljovidu Hrvatske [11, 12]



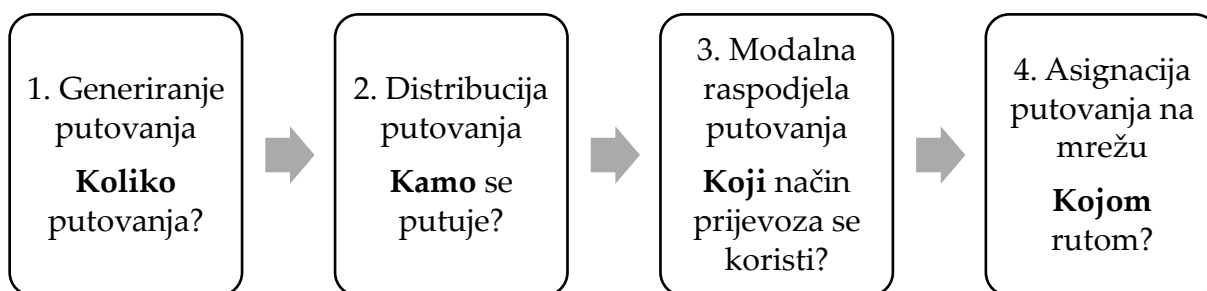
Slika 3. Prometnice u Ozlju

3. KLASIČNI ČETVEROSTUPANJSKI MODEL PROMETNE POTRAŽNJE

Klasični model prijevozne potražnje razvijen je 60 – ih godina prošlog stoljeća i do danas je ostao gotovo nepromijenjen. Razvijen je sa svrhom procjene kretanja ljudi i dobara na promatranoj prometnoj mreži te prognoziranja budućih kretanja. Pod jednom putovanjem smatra se put koji jedna osoba obavi od točke A (izvorišta putovanja) do točke B (odredište putovanja), npr. odlazak liječniku, odlazak u trgovinu, putovanje učenika do škole. [1]

Na slici 4. prikazan je opći oblik modela, koji se sastoji od četiri podmodela:

1. Generiranje ili nastajanje putovanja;
2. Distribucija ili prostorna raspodjela putovanja;
3. Modalna raspodjela putovanja;
4. Asignacija ili dodjeljivanje putovanja na mrežu.



Slika 4. Klasični četverostupanjski model prometne potražnje

Prije početka izrade modela potrebno je definirati elemente prometne mreže (linkovi, čvorovi, zone, centroidi) sa svim atributima (broj stanovnika, ulaz i izlaz vozila iz zone) te prikupiti sociološke, ekonomske i prometne podatke za kalibriranje i validiranje modela i predviđanje buduće prometne potražnje. Za prometno modeliranje prikupljanje ulaznih podataka ključan je korak, vremenski i financijski zahtjevan, no bez kvalitetno prikupljenih i obrađenih ulaznih podataka nije moguće očekivati zadovoljavajuće izlazne podatke (engl. *garbage in, garbage out*). [1]

Nakon prikupljanja podataka o broju stanovnika (podijeljenih u homogene grupe), ekonomskim aktivnostima (zaposleni, umirovljenici, studenti itd.) te namjeni površina unutar zone (tvornica, trgovački centar, škola, bolnica itd.) pristupa se izradi podmodela ukupnih putovanja koje generira i privlači svaka zona unutar promatranog područja (podmodel generiranja putovanja). Sljedeći korak je distribucija putovanja koje generira i privlači svaka zona unutar promatranog područja, nakon čega se određuje **OD** matrica (engl. *Origin – Destination Matrix*). U trećem koraku

modelira se izbor načina prijevoza između izvorišne i odredišne zone, a u završnom koraku podmodela, putovanja za svaki mod prijevoza (osobna vozila, javni gradski prijevoz) dodjeljuju se na linkove promatrane prometne mreže. [1]

Osnovna zamjerka klasičnog modela odnosi se na činjenicu da ne uzima u obzir odluke vozača u uvjetima prometnog zagušenja, kao što su promjena uobičajene rute putovanja, promjena prijevoznog sredstva, sata ili dana odlaska na putovanje. Model generiranja putovanja je neelastičan, odnosno ne uzima u obzir utjecaj razine usluge transportnog sredstva i promjena na prometnoj mreži na stvaranje putovanja. Npr. pretpostavlja da produljenje tramvajske linije na području gdje prije nije postojala neće generirati veći broj putovanja u toj zoni. Zbog toga se pokušava uvesti mjera pristupačnosti u modelu, no bez velikog uspjeha jer ju je vrlo teško definirati. [1]

3.1. Prikupljanje ulaznih podataka

Kvalitetno prikupljanje ulaznih podataka ključno je za izradu kvalitetnog modela prometa. Razlikuju se dvije osnovne metode:

1. Jednostavno slučajno uzorkovanje – najjednostavnija metoda i osnova svih ostalih metoda, metodologija se sastoji od označavanja svake jedinice populacije brojem, a nakon toga se slučajnim odabirom izvlače i utvrđuju uzorak;
2. Stratificirano slučajno uzorkovanje – prije uzorkovanja koriste se informacije kojima se populacija raspodjeljuje u homogene grupe, nakon toga se unutar definiranih grupa slučajnim odabirom odabiru jedinice koje čine uzorak. [1]

3.1.1. Metode prikupljanja podataka

Odabir najprikladnije metode prikupljanja podataka ovisi o vrsti modela koji se u prometnoj studiji, odnosno potrebnim ulaznim podacima za izradu modela. Ključni parametri u odabiru metode prikupljanja podataka su:

- Vremenski horizont za koji se izrađuje studija;
- Ograničenja u izradi studije (vremenski rok izrade studije i financijska ograničenja za izradu studije);

Kod vremenskog horizonta razlikuju se dva slučaja:

1. Kratki vremenski horizont za koji se izrađuje studija, odnosi se na prometne studije u kojima brzo treba doći do rezultata, pa makar i na uštrb kvalitete predloženog rješenja;
2. Kod strateških prometnih studija gdje je uobičajeni vremenski horizont planiranja 20 i više godina, greške u planiranju bit će vidljive tek nakon toga vremena, iz tog razloga potrebna je iznimna fleksibilnost, korištenje različitih alata kako bi se što više umanjile moguće pogreške prognožiranja. [1]

Podaci koji se koriste za izradu prometnog modela trebali bi imati sljedeće karakteristike:

- Sadrže detaljne podatke o svakoj etapi putovanja – specifikacija korištenja modova prijevoza, lokacija putovanja, vremenu putovanja itd.;
- Uključuju sve modove prijevoza pa i pješaćenje;
- Sadrže podatke o svrhama putovanja;
- Uključuju najširi mogući period (24 sata u danu, 7 dana u tjednu);
- Sadrže podatke o svim članovima kućanstva. [1]

Prikupljanje podataka na ovoj razni preciznosti nije jednostavna zadaća jer zahtjeva uključivanje velikog broja ljudi u istraživanje i provođenje anketa. Osnovne metode prikupljanja podataka u prometnom modeliranju su:

- Anketiranje kućanstva;
- Anketiranje vozača;
- Brojanje ljudi i vozila;
- Mjerenje vremena putovanja;
- Infrastrukturni objekti i podaci o prijevoznim uslugama (prometna mreža, cijena prijevoznih karata, vozni red javnog gradskog prijevoza, lokacije semaforiziranih raskrižja itd.). [1]

3.1.1.1. Anketiranje kućanstava

Anketiranje kućanstava je najkompleksnije, ali daje najbolje rezultate. Anketom se utvrđuju podaci o putovanjima svih članova kućanstva svim modovima prijevoza unutar područja promatranja. Važno je da se anketom prikupe socioekonomski podaci o dohotku, posjedovanju osobnog automobila, veličini i strukturu kućanstva itd. Preporučuje se anketiranje provoditi od sredine rujna do kraja studenoga kada su rute putovanja najviše ustaljene tijekom godine. Anketar prikuplja detaljne informacije o svim putovanjima od prošlog dana, uključujući vrijeme početka i kraja putovanja, lokaciju izvora i odredišta putovanja, svrsi putovanja, korištenim modovima prijevoza, rutama putovanja itd. Prikupljaju se i osnovni demografski podaci članova kućanstava: dob, spol, zanimanje, posjedovanje vozačke dozvole i na razni kućanstva: prosječni mjesečni prihod i posjedovanje osobnog automobila. [1]

Kod sastavljanja anketnog obrasca redoslijed pitanja treba smanjiti otpor ispitanika prema odgovoru na pitanja. Iz tog razloga „teška“ pitanja (npr. prihod kućanstva) stavljaju se na kraj obrasca. Anketni obrazac treba zadovoljiti sljedeće kriterije:

- Pitanja trebaju biti jednostavna i direktna;
- Izbjegavati nepotrebna pitanja i osigurati da svako pitanje ima određenju svrhu;
- Pitanja u kojima se očekuje od ispitanika da nešto sami napišu treba minimizirati;
- Informacija o putovanjima moraju uključiti svrhu putovanja;
- Informacije o svim korištenim modovima prijevoza tijekom putovanja;
- Svi članovi kućanstva trebaju biti uključeni u anketu.

Preporuka je da anketa bude sastavljena u dva dijela:

1. Značajke kućanstva i pojedinih članova kućanstva;
2. Podaci o putovanjima.

Ključna faza u izradi anketa je definiranje veličine uzorka, ali i odabir ažurirane baze podataka stanovnika područja u kojem će se provoditi anketa. Ako je nedavno proveden popis stanovništva mogu se koristiti ti podaci ili podaci poreznih uprava u državama gdje se oporezuju nekretnine. Primjer ankete za kućanstva o karakteristikama kućanstva i karakteristikama putovanja nalazi se na slici 5. nakon poglavlja o anketiranju vozača. [1]

3.1.1.2. Anketiranje vozača

Anketiranjem vozača određuju se podaci o putovanjima između zona promatranog područja, ali i podaci koji nisu registrirani prilikom anketiranja kućanstva (npr. tranzitna putovanja). Problem kod ovakvih istraživanja je što u mnogim državama policija ne pomaže anketarima u zaustavljanju vozila, a može doći i do lokaliziranih zastoja na prometnici. Ovakve ankete su vrlo kratke, od jedne do pet minuta i do najviše pet pitanja: svrha putovanja, izvor, odredište i ruta putovanja. Koriste se kao nadopuna anketama kućanstva tako da se na definiranim lokacijama utvrđuje broja putovanja koja ulaze, izlaze ili samo prolaze kroz promatrano područje. [1]

ANKETA KUĆANSTVA



Fakultet prometnih
znanosti,
Sveučilište u Zagrebu

Karakteristike kućanstva

Adresa:

1. Koliko članova ima kućanstvo?

Od toga starijih od 6 godina?

2. Koliko je zaposlenih članova kućanstva?

3. Koliko članova kućanstva se školuje?

Osnovna škola

Srednja škola

Fakultet

4. Koliko automobila imate u kućanstvu?

5. Koliko iznosi ukupni mjesečni prihod kućanstva?

Karakteristike putovanja

Molimo Vas da navedete po redoslijedu kretanja koja su obavili članovi kućanstva, u koje svrhe, kojim modom putovanja i u koje vrijeme?

Član kućanstva:						
Zanimanje:						
Adresa i naziv tvrtke/škole:						
Redni br.	Svrha putov.	Mod putov.	Vrijeme		Zona	
			Polaska	Dolaska	Polaska	Dolaska
1.						
2.						
3.						
4.						
5.						
6.						
7.						
8.						

Svrha putovanja:

1. Povratak kući
2. Odlazak na posao
3. Odlazak u školu
4. Odlazak u kupovinu
5. Ostalo

Mod putovanja:

1. Pješice
2. Osobni automobil
3. Autobus (JGP)
4. Tramvaj (JGP)
5. Autobus i tramvaj (JGP)
6. Ostalo

Slika 5. Primjer anketnog lista

3.2. Definiranje parametara prijevozne ponude

Jedna od najvažnijih odluka u prometnom modeliranju je odlučivanje o razini detaljnosti prometnog modela. Pri tome treba uravnotežiti odnos točnosti modela i troškova izrade. Veća točnost modela može se postići koristeći detaljnije zoniranje itd. U stvarnosti putovanja mogu započeti i završiti na bilo kojoj adresi u svijetu i koristiti svu dostupnu prometnu mrežu. Kako bi se riješio specifični transportni problem nije potrebno prometni sustav prikazati s najvećom razinom detaljnosti nego se pojednostavljuje kako bi se olakšalo rješavanje zadanog problema. [1]


3.2.1. Zoniranje

Zoniranje ili raspodjela analiziranog područja na prometne zone koriste se za okrupnjavanje individualnih kućanstava i drugih prostora u homogene skupine radi lakšeg korištenja u prometnom modeliranju. Zone predstavljaju geografska područja između kojih se definira i računa broj putovanja.

Prvi korak u definiranju sustava zoniranja je prostorno razgraničiti područje analize od ostatka područja. U definiranju tih granica predlaže se:

- Definirati granice u skladu s kontekstom donošenja odluka, scenarija koji će se modelirati i o vrsti putovanja koja će se analizirati, npr. ako se analizira nacionalna mreža željeznice tada će područje analize biti cijela država, ali i susjedne države;
- Kod strateških studija treba težiti da većina putovanja ima izvorište i odredište putovanja u području analize, što nije moguće u manjim gradskim sredinama gdje je većina putovanja u tranzitu, također u manjim sredinama je često odredište ili izvorište putovanja izvan područja analize (npr. putovanja na posao ili u školu u drugi grad).

Nakon utvrđivanja područja analize, područje se dijeli na unutarnje zone kao što je prikazano na slici 6.



Slika 6. Prometne zone regije Hauge – Rotterdam u Nizozemskoj [1]

U programskim alatima zone su prezentirane centroidom zone koji predstavlja točku unutar zone u kojoj su koncentrirani svi atributi i značajke zone. Centroid zone nije neka fizička točka unutar zone, već ga je bolje zamisliti kao točku koja lebdi iznad zone. Lokaciju centroida treba odabrati tako da predstavlja centar gravitacije zone. Vrijeme putovanja i udaljenost između zona računa se između centroida zona. Centroidi su povezani s prometnom mrežom pomoću konektora koji predstavljaju prosječni trošak (udaljenost, vrijeme) uključivanja nekog putovanja u prometni sustav. Konektori se vežu za čvorove ulaska i izlaska iz zone. [1]

Definiranje granica, sadržaja i broja zona zahtjeva iskustvo prometnog modelara, a mogu se izdvojiti neki kriteriji zoniranja:

1. Veličina zone treba biti takva da je greška okrupnjavanja svih aktivnosti zone u centroidu minimalna, preporuka je da se prvo počinju formirati male zone, koje se kasnije prema potrebi mogu spajati s drugim zonama;
2. Sustav zoniranja trebao bi biti kompatibilan s administrativnim granicama;
3. Zone trebaju biti što je više homogene u namjeni zemljišta i strukturi populacije;
4. Oblik zone treba biti takav da omogućuje lako utvrđivanje njezinog centroida i konektora;
5. Zone ne trebaju biti iste veličine, preporučuje se definiranje granice zona prema vremenu putovanja, zato je u zagušenim područjima potrebno formirati više manjih zona, a u ne zagušenim područjima veće zone;
6. Posebne zone treba definirati za velike aktore (područje koje privlači velik broj putovanja; trgovački centar) i produkte (područje gdje započinje velik broj putovanja; stambena zona) putovanja kao što su obrazovne ustanove, bolnice, tvornice, poslovne zone, zračne luke, trgovački centri itd.;
7. Na svim ulazima u grad i izlazima iz grada potrebno je definirati vanjske zone, čija produkcija (broj putovanja koja izlaze iz zone) i atrakcija (broj putovanja koja ulaze u zonu) putovanja se može procjenjivati iz brojanja prometa. [1]

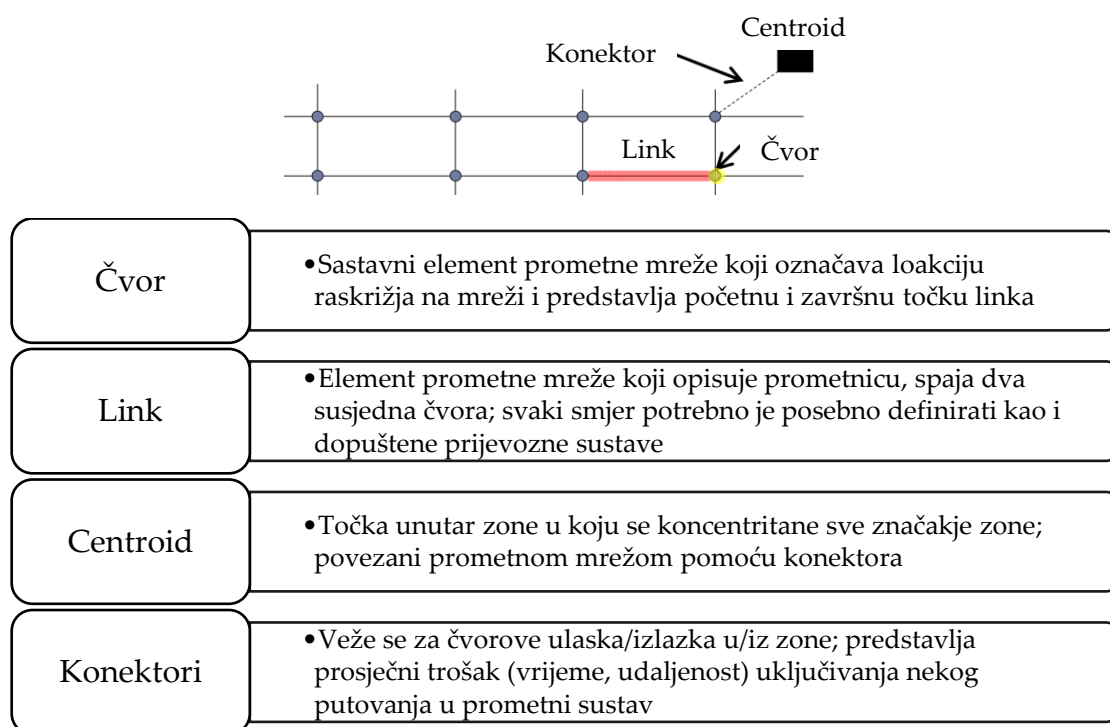
3.2.2. Prometna mreža

Prometna mreža predstavlja ključnu komponentu prijevozne ponude prometnog modela. Prikazuje se kao sustav čvorova (raskrižja) međusobno povezanih linkovima (prometnicama) kao na slici 6. Čvorovi predstavljaju raskrižja prometne mreže, a linkovi prometnice između raskrižja. Linkovi su prikazani sa svojim atributima poput kapaciteta, dužine, broja trakova, postotka teških vozila itd.

Čvorovi su sastavni element prometne mreže i označavaju lokacije raskrižja na mreži te predstavljaju početnu i završnu točku linka. Osim lokacije čvora, u svrhu proračuna propusne moći, potrebno je definirati način upravljanja prometnim tokovima (semafor, prometni znakovi, kružno raskrižje) te dopuštene i zabranjene smjerove kretanja. Definiranje propusne moći linkova vrlo je važno u uvjetima gradskog prometnog opterećenja s obzirom na to da oni predstavljaju najveće otpore (troškove) putovanja na ruti kretanja. Troškovi (otpori) putovanja mogu biti promatrani kao prijeđena udaljenost, vrijeme putovanja, novčani troškovi putovanja... Troškovi putovanja ne bi se trebali razmatrati zasebno potrebno ih je svesti na zajedničku mjernu jedinicu. Postupak računanja generaliziranog troška putovanja je u poglavlju 3.4.1. Generalizirani trošak putovanja.

Ako je potrebno modelirati i javni gradski prijevoz tada osim čvorova i linkova treba definirati i linije javnog gradskog prijevoza sa stajalištima na promatranoj prometnoj mreži.

Linkovi su elementi prometne mreže koji opisuju prometnice, odnosno spajaju dva susjedna čvora, svaki smjer potrebno je posebno definirati, kao i dopuštene transportne sustave. Jedan od prvih koraka u izradi prometnog modela je provođenje klasifikacije linkova i utvrđivanje propusne moći. Ovaj korak je iznimno važan s obzirom na to da propusna moć utječe na proračun vremena putovanja na linkovima mreže. Klasifikacija linkova omogućuje i automatsko definiranje prioriteta tokova na raskrižjima. Klasifikacija linkova prikazana je u tablici 1. [1]



Slika 7. Osnovni elementi prometne mreže [1]

Tablica 1. Klasifikacija prometnica [1]

Vrsta prometnice	Propusna moć po traku, voz/h	Brzina slobodnog toka, km/h	Značajke
Autocesta	2400	> 100	<ul style="list-style-type: none"> • Velike brzine putovanja • Zone uplitanja i isplitanja • Dozvoljeno prometovanje samo motornih vozila • Povezuju velike gradove • Naplata cestarine • Tranzitni promet
Obilaznica	2000	≥ 70	<ul style="list-style-type: none"> • Velike brzine putovanja • Razdjelni pojas • Ograničen broj ulaza i izlaza • Dozvoljeno prometovanje samo motornih vozila • Tranzitni promet
Vezna cesta	1900	50 – 70	<ul style="list-style-type: none"> • Pješački nogostup i biciklističke staze • Semaforizirana i nesemaforizirana raskrižja • Prometna zagušenja • Parkiranja uz rub ceste
Sabirna cesta	1800	50	<ul style="list-style-type: none"> • Povezuju stambena naselja s veznim cestama • Pješački i biciklistički promet • Česta radna vozila i strojevi • Vode do velikih atraktora i produkatora putovanja
Pristupna cesta	1600	40	<ul style="list-style-type: none"> • Male brzine vožnje • Uzak poprečni profil, čestom s jednim prometnim trakom za oba smjera • Ceste kroz gradske četvrti

3.2.3. Prijevozni sustavi

Prijevozna ponuda sastoji se od nekoliko prijevoznih sustava. Pet je osnovnih prijevoznih sustava kojima putnici povezuju izvor i odredište putovanja:

1. Osobna vozila – vrijeme putovanja ovog sustava ovisi o najvećim brzinama koje mogu ostvariti pojedini modovi prijevoza, najvećoj zakonski dopuštenoj brzini na pojedinom linku i propusnoj moći linkova;
2. Javni prijevoz – ključni ulazni podaci su vozni red i vrijeme izmjene putnika na stajalištima;
3. Pješaćenje;
4. Vožnja biciklom;
5. Kombinacije prethodnih prijevoznih sustava.

Osim prijevoznih sustava potrebno je definirati i modove prijevoza koji pripadaju svakom od tih sustava: osobni automobil, tramvaj, vlak, podzemna željeznica... Kako bi se povezala prijevozna ponuda i potražnja svakom modu je potrebno dodijeliti odgovarajuću OD matricu. [1]

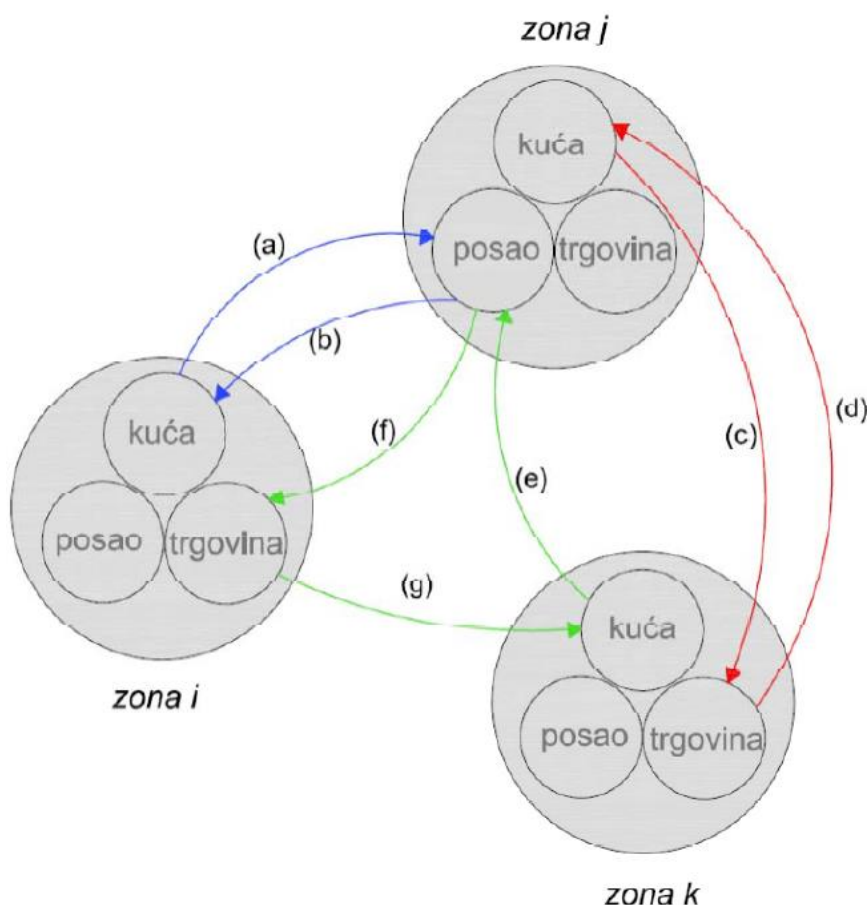
3.3. Podmodel generiranja putovanja

U prvom koraku četverostupanjskog prometnog modela procjenjuje se ukupan broj putovanja koje koji se generira u zoni O_i i privlači u analiziranom području D_j . To se može postići na više načina, analizirajući putovanja svakog pojedinca ili kućanstva unutar zone te iz atributa svake zone (populacija, zaposlenost, broj automobila).

Kod putovanja baziranih na kućanstvu definirano je nekoliko vrsta putovanja:

- Putovanja na posao;
- Putovanja u školu ili fakultet;
- Putovanja u kupovinu;
- Socijalna i rekreacijska putovanja;
- Ostala putovanja.

Osim prema svrsi putovanja ona se kategoriziraju i prema dobu dana kada se odvijaju, najčešće na putovanja u vršnom i izvanvršnom periodu. [1]



Slika 8. Produkcija i atrakcija putovanja prema izvoru i odredištu [1]

3.3.1. Regresijska analiza

Metoda regresijske analize koristi se kako bi se utvrdila statistička ovisnost između ostvarenih putovanja i značajka pojedinca, zone i prometne mreže. Koristi se kako bi se iz prikupljenih podataka mogla izvesti jednadžba ukupnog broja putovanja neke zone. Ako se utvrdi nezadovoljavajući koeficijent determinacije $R^2 < 0,75$, može se povećanjem uzorka pokušati povećati njegova vrijednost.


Najjednostavniji način izračuna jednadžbe linearne regresije je pomoću *MS Office Excela*. Primjer izračuna je u nastavku.

Primjer 1. [13]

Grad je podijeljen na sedam zona i za svaku zonu dan je broj putovanja i broj vlasnika automobila (tablica 2.). Potrebno je odrediti jednadžbu pravca linearne regresije i koeficijent determinacije. Rješenje primjera i grafički prikaz nalaze se na slici 9.

Tablica 2. Ulazni podaci

Zona	1	2	3	4	5	6	7
Broj putovanja, x	500	300	1300	400	300	1000	900
Broj vlasnika automobila, y	200	50	1000	200	300	800	500



Slika 9. Pravac regresije i koeficijent determinacije

S obzirom na česti problem nelinearnosti, regresijska analiza danas se kod definiranja produkcije putovanja najčešće zamjenjuje kategorijskom analizom. Kod procjenjivanja atrakcije putovanja po zonama i dalje se koristi regresijska analiza.

U modelu produkcije, procjene su bazirane na demografskim karakteristikama populacije unutar zone. Kod utvrđivanja atrakcije pojedinih zona najboljima su se pokazale varijable bazirane na značajkama namjene zemljišta i stopi zaposlenosti unutar zone.

U Republici Hrvatskoj ne postoje podaci o faktorima atrakcije i produkcije pojedinih građevinskih objekata (škola, bolnica, trgovački centar). Stoga se koriste podaci iz priručnika *Trip Generation* [14] američkog Instituta prometnih inženjera ITE (engl. *Institute of Transportation Engineers*) kao polazni parametar. Faktori generiranja putovanja za kuću i stan prikazani su na slikama 9. i 10.

Priručnik *ITE Trip Generation* baziran je na 4 800 studija faktora generiranja putovanja u SAD - u. Podaci su skupljani u prigradskim područjima bez javnog prijevoza. Faktor generiranja putovanja predstavlja broj putovanja koja ostvaruje jedno kućanstvo ili pojedinac, a može se računati i po površini promatranih objekata. U priručniku se nalaze podaci o periodu za koji se računa faktor generiranja putovanja, odnosi između produkcije i atrakcije i regresijski pravac s koeficijentom determinacije R^2 .

Obiteljska kuća

Prosječan broj putovanja po: Stambenoj jedinici (obiteljska kuća)

Period: Radni dan, jutarnji vršni sati (od 7 h do 9 h)


Broj studija: 284

Prosječan broj obiteljskih kuća: 194

Raspodjela putovanja: 25 % ulazi, 75 % izlazi

Broj generiranih putovanja

Prosjek	Raspon	Standardna devijacija
0,75	0,33 – 2,27	0,90



Slika 10. Faktori generiranja putovanja za kuću [14]

Stan

Prosječan broj putovanja po: Stambenoj jedinici (stan)

Period: Radni dan, jutarnji vršni sati (od 7 h do 9 h)


Broj studija: 90

Prosječan broj obiteljskih kuća: 233

Raspodjela putovanja: 35 % ulazi, 65 % izlazi

Broj generiranih putovanja

Prosjek	Raspon	Standardna devijacija
0,62	0,10 – 1,64	0,82



Slika 11. Faktor generiranja putovanja za stan [14]

3.3.2. Kategorijska analiza

Kategorijska analiza je najčešće korištena metoda za utvrđivanje produkcije putovanja. Bazirana je na procjeni broja putovanja koja se stvaraju ili privlače ovisno o atributima kućanstva. Osnovna pretpostavka je da je stopa generiranja putovanja relativno stabilna kroz vrijeme za pojedine grupe kućanstva. Stope generiranja putovanja za svaki tip kućanstva utvrđuju se empirijski, na temelju velikog broja podataka iz anketnih istraživanja. Kao što je prije navedeno kućanstva u anketi upisuju svako putovanje koje su objavili proteklog dana, izvorište, odredište svrhu i vrijeme putovanja.

Primjer 2. [13]

Prema socioekonomskim istraživanjima analiziranog područja utvrđene su sljedeće značajke važne za kategorijsku analizu.

Prihod kućanstava:

1. Manje od 5000 kn – nizak prihod;
2. Od 5000 kn do 10000 kn – srednji prihod;
3. Više od 10000 kn – visok prihod.

Broj automobila po kućanstvu:

1. Ni jedan (0);
2. Jedan (1);
3. Dva i više (2+).

Struktura kućanstva:

1. 1 – 3 osobe u kućanstvu;
2. 4 i više osoba.

Anketiranjem uzorka kućanstava definirani su sljedeći faktori generiranja putovanja:

Tablica 3. Faktori generiranja putovanja

Broja automobila po kućanstvu	Broj članova kućanstva	Prihodi po kućanstvu		
		Nizak	Srednji	Visok
Nula (0)	1 – 3	3,4	3,6	3,9
	4 i više	4,9	5,1	5,2
Jedan (1)	1 – 3	5,2	7,3	7,9
	4 i više	6,9	8,3	10,2
Dva i više (2+)	1 – 3	5,8	8,0	10,8
	4 i više	7,2	11,6	12,8

Potrebno je odrediti produkciju putovanja analiziranog područja prema podacima u tablici 3.

- a) 100 kućanstva s niskim prihodom, bez automobila i 3 člana

$$O_{1a} = N_{ka} \cdot F_{gpa} = 100 \cdot 3,4 = 340 \text{ putovanja} \quad (1)$$

- b) 200 kućanstva s niskim prihodom, bez automobila i 4 člana

$$O_{1b} = N_{kb} \cdot F_{gpb} = 200 \cdot 4,9 = 980 \text{ putovanja} \quad (2)$$

- c) 300 kućanstva sa srednjih prihodom, s jedni automobilom i 4 člana

$$O_{1c} = N_{kc} \cdot F_{gpb} = 300 \cdot 8,3 = 2490 \text{ putovanja} \quad (3)$$

- d) 50 kućanstva s visokim prihodom, s dva automobila i 5 člana

$$O_{1d} = N_{kd} \cdot F_{gpb} = 50 \cdot 12,8 = 640 \text{ putovanja} \quad (4)$$

3.3.3. Usklađivanje produkcije i atrakcije putovanja

Prethodno analizirani modeli ne uvjetuju da će zbroj svih putovanja koja nastaju u promatranom području biti jednaka zbroju svih putovanja koja su privučena u zone. Naime, prilikom stvaranja **OD** matrice putovanja, sva putovanja koja su nastala u nekoj zoni, moraju završiti u drugim zonama, odnosno ne mogu nestati iz analiziranog područja. Zapisano u obliku jednadžbe glasi:

$$\sum_i O_i = \sum_j D_j \quad (5)$$

U jednadžbi (5) O_i predstavlja ukupan broj putovanja koja nastaju na promatranom području (produkcija), a D_j ukupan broj putovanja koja su privučena u analizirano područje (atrakcija).

S obzirom da su modeli za procjenu produkcije putovanja kvalitetniji od onih za atrakciju putovanja, u pravilu se ukupan zbroj atrakcije prilagođava ukupnom zbroju produkcije. Vrijednost produkcije su konstante, a vrijednosti atrakcije se prilagođavaju kako bi njihov ukupan broj odgovarao zbroju produkcije svih zona pomoću jednadžbe (6), gdje je f faktor povećanja produkcije.

$$f = \frac{\sum_i O_i}{\sum_j D_j} \quad (6)$$

3.4. Podmodel distribucije putovanja

U drugom koraku četverostupanjskog prometnog modela produkcija i atrakcija prethodno su definirane i daju podatke o generiranju putovanja u analiziranom području koji nisu dovoljni za prometno modeliranje i donošenje odluka. Potrebno je odrediti otkuda i kamo se ostvaruju putovanja.

Izvorište i odredište putovanja, kao i broj putovanja između njih u nekom periodu prikazuje se izvorišno – odredišnom matricom putovanja, **OD** matricom koja može biti dezagregirana prema aktivnostima koje se provode (posao, trgovina, obrazovanje itd.), homogenoj skupini putnika (studenti, radnici, umirovljenici i sl.) te modovima prijevoza (osobna vozila, javni gradski prijevoz).

U nekim europskim zemljama (Njemačka, Italija, Ujedinjeno Kraljevstvo) provode se istraživanja u svrhu utvrđivanja **OD** matrica. Određivanjem **OD** matrica preskaču se prva tri koraka izrade četverostupanjskog modela, jer su određene **OD** matrice prema vrstama prijevoznog sredstva te se provodi samo četvrti korak, odnosno dodjeljivanje putovanja na mrežu kako bi se utvrdila prometna opterećenost prometnica i linija javnog gradskog prijevoza. [1]

U tablici 4. prikazan je opći oblik **OD** matrice koja se sastoji od:

T_{ij} – broj putovanja između izvorišne zone „ i “ i odredišne zone „ j “;

T – ukupan broj putovanja između svih zona;

O_i – ukupan broj putovanja koja nastaju u zoni „ i “;

D_j – ukupan broj putovanja koja su privučena u zonu „ j “.

Tablica 4. Prikaz općeg oblika **OD** matrice

		Odredišta putovanja					
		1	2	3	...	j	$\sum_j T_{ij}$
Izvorišta putovanja	1	T_{11}	T_{12}	T_{13}	...	T_{1j}	O_1
	2	T_{21}	T_{22}	T_{23}	...	T_{2j}	O_2
	3	T_{31}	T_{32}	T_{33}	...	T_{3j}	O_3

	i	T_{i1}	T_{i2}	T_{i3}	...	T_{ij}	O_i
	$\sum_i T_{ij}$	D_1	D_2	D_3	...	D_j	$\sum_{ij} T_{ij} = T$

Ukupan zbroj svih putovanja u svakom retku **OD** matrice mora odgovarati ukupnom broju putovanja koja nastaju u toj zoni, odnosno ukupan zbroj putovanja u svakom stupcu mora odgovarati broju putovanja koja su privučena u svaku od zona. Kako bi ovi uvjeti bili ispunjeni u prvom koraku četverostupanjskog modela potrebno je izjednačiti produkciju i atrakciju svih zona. Zapisano u obliku jednadžbe glasi:

$$\sum_i T_{ij} = O_i; \sum_j T_{ij} = D_j \quad (7)$$

Tijekom povijesti razvilo se nekoliko modela za utvrđivanje distribucije putovanja između zona:

- Gravitacijski model;
- Model faktora porasta;
- Model maksimizacije entropije.

3.4.1. Generalizirani trošak putovanja

Troškovi ili otpori putovanju mogu biti razmatrani kao prijedena udaljenost, vrijeme putovanja, novčani troškovi itd. S obzirom na to da troškove putovanja ne treba razmatrati zasebno, potrebno ih je generalizirati, odnosno svesti na zajedničku mjernu jedinicu. Generalizirani trošak putovanja predstavlja mjeru koja u sebi kombinira sve glavne attribute koji se odnose na otpore odabranog putovanja. To je najčešće linearna funkcija atributa putovanja s ponderiranim koeficijentima koji prezentiraju važnost tih atributa percipiranu od strane putnika. Generalizirani trošak putovanja predstavlja kompromis između objektivnih i subjektivnih prepreka u nastajanju putovanja. [1]

3.4.2. Gravitacijski model

Danas se najviše koristi gravitacijski model za predviđanje putovanja između zona prometne mreže. Ovaj model proizlazi iz analogije Newtonovog zakona gravitacije, prema kojem je sila privlačenja između dva tijela proporcionalna masama tih tijela, a obrnuto proporcionalna kvadratu udaljenosti među njima. Analogno u području prometnog modeliranja, interakcija dvaju zona ovisi o snazi generiranja odnosno privlačenja putovanja tih zona i njihovoj udaljenosti. [1]

Prvi oblik gravitacijskog modela predložio je H. J. Casey u radu „*Applications to traffic engineering of the law of retail gravitation*“ [15]. Model koji je predložio sintetizira putovanja u svrhu kupovine i zone dohvata između gradova regije. U svom najjednostavnijem obliku gravitacijski model ima sljedeće oblik:

$$T_{ij} = \frac{\alpha \cdot P_i \cdot P_j}{d_{ij}^2} \quad (8)$$

Gdje je:

T_{ij} – broj putovanja između izvorišne zone „i“ i odredišne zone „j“;

α – kalibracijska konstanta;

P_i, P_j – populacije zone „i“, odnosno „j“, stanovnika;

d_{ij} – udaljenost zona „i“ i „j“, km.

Uskoro je utvrđeno da je ovaj model prejednostavan te se predlaže uključivanje ukupnog broja putovanja koja nastaju u zoni O_i i ukupnog broja putovanja koja su privučena u zonu D_j umjesto ukupnog broja stanovnika. S obzirom na to da se korištenje samo troškova putovanja nije pokazalo najboljim rješenjem s obzirom na specifičnost putovanja u svakom gradu model se još više generalizira. Generalizacija se provodi pod pretpostavkom da se udaljenost koju putnik mora prijeći između zona bolje može opisati padajućom distribucijskom funkcijom generaliziranog troška putovanja $f(c_{ij})$. Ova distribucijska funkcija prikazuje otpor putnika prema putovanju kako se povećavaju troškovi putovanja.

$$T_{ij} = \alpha \cdot O_i \cdot D_j \cdot f(c_{ij}) \quad (9)$$

Gdje je:

α – kalibracijska konstanta;

O_i – ukupan broj putovanja koja nastaju u zoni „i“;

D_j – ukupan broj putovanja koja su privučena u zonu „j“;

$f(c_{ij})$ – generalizirana distribucijska funkcija troškova putovanja;

c_{ij} – generalizirani trošak putovanja;

Generalizirana distribucijska funkcija putovanja $f(c_{ij})$ sadrži jedan ili više parametara koje je potrebno kalibrirati, a pojavljuje se u nekoliko oblika:

a) Eksponencijalna funkcija

$$f(c_{ij}) = e^{-\beta \cdot c_{ij}} \quad (10)$$

Osobitost ove funkcije je da apsolutni porast vremena putovanja ima za posljedicu relativni pad želje za stvaranjem putovanja. Iz tog razloga se smatra da ova funkcija nije točna kada prijeđene udaljenosti prelaze 15 km.

b) Funkcija potencije

$$f(c_{ij}) = c_{ij}^{-n} \quad (11)$$

Koristi se kod velikih udaljenosti i velikih generaliziranih troškova. Kod malih udaljenosti ne pokazuje dobre rezultate. Vrlo rijetko se koristi u praksi.

c) Kombinirana (Tannerova) funkcija

$$f(c_{ij}) = a \cdot c_{ij}^{-n} \cdot e^{-\beta \cdot c_{ij}} \quad (12)$$

Ne uzima u obzir uvjet da mora biti monotono padajuća pa se najčešće koristi za raspodjelu putovanja kada je dostupan samo jedan oblik prijevoznog sredstva (unimodalna raspodjela). [1]

U praksi se najčešće koristi oblik gravitacijskog modela uravnotežen po produkciji:

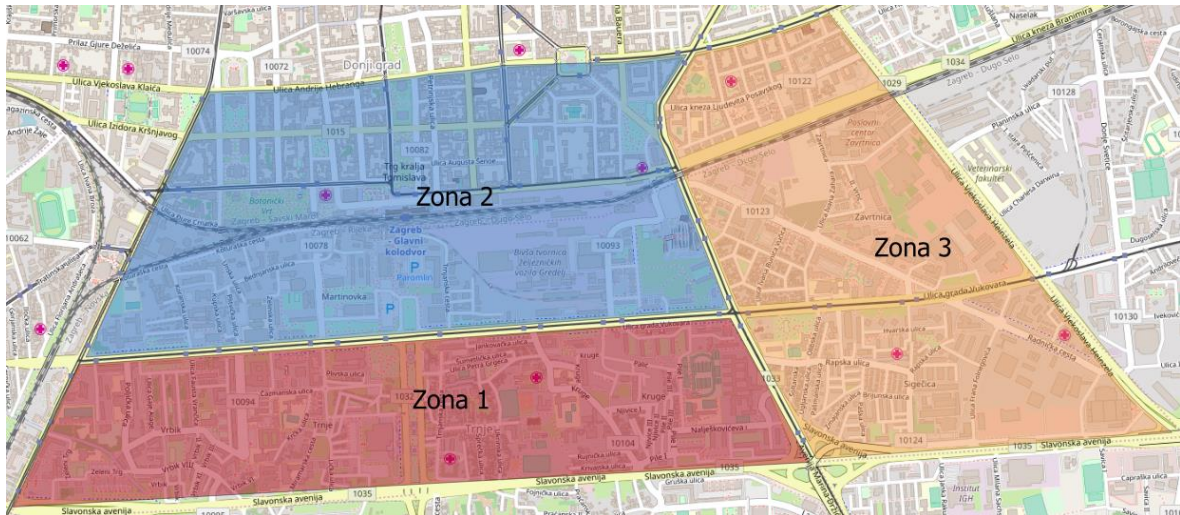
$$T_{ij} = \frac{O_i \cdot D_j \cdot f(c_{ij})}{\sum_{j=1}^n (D_j \cdot f(c_{ij}))} \quad (13)$$

Prema iskustvu pokazalo se da kod generiranja putovanja utvrđene produkcije zona bolje opisuju stvarno stanje od atrakcije zona.

U nastavku je numerički primjer koji ilustrira primjenu gravitacijskog modela distribucije putovanja.

Primjer 3.[13]

Na slici 12. prikazan je grad podijeljen u tri prometne zone. Podaci o produkciji i atrakciji zona nalaze se u tablici 5., a vremena putovanja između zona nalaze se u tablici 6. Na temelju tih podataka potrebno je odrediti OD matricu putovanja za grad. Kao troškove putovanja pretpostaviti funkciju potencije s eksponentom $n = -1$.



Slika 12. Grad podijeljen na zone

Tablica 5. Podaci o produkciji i atrakciji zona

Zona	Produkcija O_i	Atrakcija D_j
1	240	220
2	120	220
3	300	220
Σ	660	660

Tablica 6. Vremena putovanja između zona

Vrijeme putovanja c_{ij}	1	2	3
1	1	4	6
2	4	1	6
3	7	7	1

Za izračun troškova putovanja uzima se funkcija potencije prikazana u jednadžbi (11) s eksponentom $n = -1$. Rezultati izračuna generaliziranog troška putovanja između zona nalaze se u tablici 7. Funkcija generaliziranog troška putovanja:

$$f(c_{ij}) = c_{ij}^{-1} \quad (14)$$

Tablica 7. Generalizirani trošak putovanja između zona

Generalizirani trošak putovanja $f(c_{ij})$	1	2	3
1	1,00	0,25	0,17
2	0,25	1,00	0,17
3	0,14	0,14	1,00

Nakon izračuna generaliziranog troška putovanja, provodi se raspodjela putovanja pomoću jednadžbe (13). Raspodjela putovanja između zona:

$$T_{ij} = \frac{O_i \cdot D_j \cdot f(c_{ij})}{\sum_{j=1}^n (D_j \cdot f(c_{ij}))} \quad (15)$$

$$T_{11} = \frac{240 \cdot 220 \cdot 1,00}{220 \cdot 1,00 + 220 \cdot 0,25 + 220 \cdot 0,17} = 169,41 \text{ putovanja} \quad (16)$$

$$T_{12} = \frac{240 \cdot 220 \cdot 0,25}{220 \cdot 1,00 + 220 \cdot 0,25 + 220 \cdot 0,17} = 42,35 \text{ putovanja} \quad (17)$$

$$T_{13} = \frac{240 \cdot 220 \cdot 0,17}{220 \cdot 1,00 + 220 \cdot 0,25 + 220 \cdot 0,17} = 28,24 \text{ putovanja} \quad (18)$$

Za raspodjelu putovanja između ostalih zona provodi se analogan postupak i određuje se **OD** matrica prikazana u tablici 8.

Tablica 8. **OD** matrica za promatrani grad nakon prve iteracije

T_{ij}	1	2	3	O_i
1	169,41	42,35	28,24	240,00
2	21,18	84,71	14,12	120,00
3	33,33	33,33	233,33	300,00
D_j	223,92	160,39	275,69	660,00

Nakon provjere, odnosno zbrajanja produkcije i atrakcije zasebno dolazi se do zaključka da su produkcija i atrakcija jednake i iznose 660 putovanja i nije potrebno izvoditi daljnje iteracije, samo je potrebno „zaokružiti“ broj putovanja na cijeli broj. U tablici 9. prikazane je konačna **OD** matrica.

Tablica 9. Konačna **OD** matrica za promatrani grad

T_{ij}	1	2	3	O_i
1	170	42	28	240
2	21	85	14	120
3	33	33	234	300
D_j	224	160	276	660

3.4.3. Modeli faktora porasta

Modeli faktora porasta rijetko se koriste, a služe najviše za ažuriranje OD matrica putovanja određena iz prošlih istraživanja, kao i za procjenu putovanja u budućem razdoblju, a dijele se na:

- Model jedinstvenog faktora porasta;
- Model prosječnog faktora rasta;
- Fratar model;
- Detroit model.

Najznačajniji od prethodno navedenih modela je Fratar model kojim se pretpostavlja da je razdioba budućih prometnih težnji iz zone „j” proporcionalna razdiobi sadašnjih težnji, modificiranih s čimbenikom težnje zone kojoj je promet upućen. [16] Buduća kretanja putovanja iz zone „i” u zonu „j” moguće je opisati jednadžbom:

$$T_{ij} = t_{ij} \cdot F_i \cdot F_j \cdot \frac{\sum_{k=1}^n t_{ik}}{\sum_{k=1}^n (F_k \cdot t_{ik})} \quad (19)$$

Gdje je:

T_{ij} – budući broj putovanja iz zone „i” u zonu „j”, putovanja;

t_{ij} – sadašnji broj putovanja iz zone „i” u zonu „j”, putovanja;

F_i, F_j – faktori porasta;

t_{ik} – sadašnje kretanje prometa s izvorom u zoni „i” i ciljem u zoni „k”;

F_k – faktor porasta zone „k”.

3.5. Podmodel modalne raspodjele putovanja

Odabir moda prijevoza jedan je od najvažnijih koraka u klasičnom transportnom modelu s obzirom da ima značajan utjecaj na prometno planiranje i prometnu politiku određenog grada. Odabir vrste (moda) prijevoza (osobni automobil, javni gradski prijevoz, pješaćenje, bicikl) ovisi o dostupnosti moda prijevoza i troškovima prijevoza, a značajno utječe i svrha putovanja. Primjerice, prednost će se dati odabiru osobnog automobila kod putovanja u noćni izlazak na mjesto gdje javni prijevoz ima vrlo rijetke intervale vožnje ili ga uopće nema.

Faktori koji utječu na odabir vrste prijevoza mogu se podjeli u tri grupe značajki:

1. Značajke putnika:

- Posjedovanje osobnog automobila;
- Posjedovanje vozačke dozvole;
- Struktura kućanstva;

2. Značajke putovanja:

- Svrha putovanja (putovanje na fakultet obično je jednostavnije izvesti javnim gradskim prijevozom zbog njegove redovitosti);
- Doba dana u kojem se ostvaruje putovanje (noćna putovanja teže je izvesti javnim gradskim prijevozom)
- Da li se putovanje ostvaruje samostalno ili s drugim putnicima.

3. Značajke prometnog sustava:

- Komponente vremena putovanja;
- Komponente novčanih troškova (karta, cestarina, parking);
- Pouzdanost vremena putovanja i redovitost usluge. [1]

3.5.1. Diskretni model odabira

Jedna od najvećih inovacija u analizi prijevozne potražnje je razvoj dezagregiranih (razjedinjenih) modela prijevozne potražnje. Takvi modeli, za razliku od agregiranih gdje atributi svih putnika koncentrirani u centroidu zone, procjenjuju parametre na temelju individualnih značajki putnika. Osnovni problem analize diskretnog odabira je modeliranje izbora između skupa različitih varijanti. Kao rješenje uzima se maksimizacija korisnosti. Donositelj odluke odabire varijantu s najvećom korisnosti u periodu odabira. Model se sastoji od funkcije koja se sastoji od nezavisnih varijabli i nepoznatih parametara koji se procjenjuju iz uzorka. Neki od diskretnih modela odabiru su binarni i multinomijalni Logit model. [1]

3.5.1.1. Binarni Logit model

Koristi se za izračun raspodjele putovanja kada su moguća samo dva moda prijevoza. Korisnost moda prijevoza računa se pomoću težinskog koeficijenta kojim se množi određeni atribut putovanja (vrijeme putovanja, vrijeme čekanja, troškovi prijevoza i dr.). Izračun vjerojatnosti za pojedini mod prijevoza računa se:

$$P_n(i) = \frac{e^{\mu \cdot V_{in}}}{e^{\mu \cdot V_{in}} + e^{\mu \cdot V_{jn}}} \quad (20)$$

Gdje je:

$P_n(i)$ – vjerojatnost za pojedini mod prijevoza;

μ – kalibracijski parametar;

V_{in} – korisnost pojedinog moda prijevoza.

3.5.1.2. Multinomijalni Logit model

Multinomijalni modeli koriste se kada postoji više modova prijevoza (ne samo dva). Modovi prijevoza mogu biti: vožnja automobilom, zajednička vožnja automobilom, taxi, bicikl, pješčenje, željeznica itd. Zapisano u obliku jednadžbe glasi:

$$P_n(i) = \frac{e^{\mu \cdot V_{in}}}{\sum_j e^{\mu \cdot V_{jn}}} \quad (21)$$

Gdje je:

$P_n(i)$ – vjerojatnost za pojedini mod prijevoza;

μ – kalibracijski parametar;

V_{in} – korisnost pojedinog moda prijevoza.

U primjeru 4. je izračun raspodjele putovanja koristeći multinomijalni Logit model.

Primjer 4. [13]

Koristeći multinomijalni Logit model potrebno je raspodijeliti 2000 putovanja od točke A do točke B. Kao varijante ponuđena su tri moda prijevoza: automobil, autobus i tramvaj. Značajke modova nalaze se u tablici 10.

Tablica 10. Značajke modova prijevoza

	Vrijeme putovanja t_{put} , min	Vrijeme pješčenja do moda prijevoza t_{pj} min	Vrijeme čekanja vozila JGP $t_{\check{c}}$, min	Troškovi prijevoza tr , kn	Cijena parkinga tp , kn
μ_n	0,04	0,05	0,07	0,15	0,15
Automobil (1)	15	-	-	15	5
Autobus (2)	25	6	4	6	-
Tramvaj (3)	10	8	3	4	-

Prvo je potrebno izračunati korisnost pojedinog moda prijevoza. Funkcija korisnosti je linearna gdje se svaki trošak množi s odgovarajućim ponderirajućim koeficijentom.

Izračun korisnosti modova:

$$\begin{aligned} V_1 &= -\mu_1 \cdot t_{put_1} - \mu_2 \cdot t_{pj_1} - \mu_3 \cdot t_{\check{c}_1} - \mu_4 \cdot tr_1 - \mu_5 \cdot tp_1 \\ &= -0,04 \cdot 15 - 0,05 \cdot 0 - 0,07 \cdot 0 - 0,15 \cdot 15 - 0,15 \cdot 5 = -3,80 \end{aligned} \quad (22)$$

$$\begin{aligned} V_2 &= -\mu_1 \cdot t_{put_2} - \mu_2 \cdot t_{pj_2} - \mu_3 \cdot t_{\check{c}_2} - \mu_4 \cdot tr_2 - \mu_5 \cdot tp_2 \\ &= -0,04 \cdot 25 - 0,05 \cdot 6 - 0,07 \cdot 4 - 0,15 \cdot 6 - 0,15 \cdot 0 = -4,20 \end{aligned} \quad (23)$$

$$\begin{aligned} V_3 &= -\mu_1 \cdot t_{put_3} - \mu_2 \cdot t_{pj_3} - \mu_3 \cdot t_{\check{c}_3} - \mu_4 \cdot tr_3 - \mu_5 \cdot tp_3 \\ &= -0,04 \cdot 10 - 0,05 \cdot 8 - 0,07 \cdot 3 - 0,15 \cdot 4 - 0,15 \cdot 0 = -3,02 \end{aligned} \quad (24)$$

Kada je poznata korisnost pojedinog moda prijevoza, izračunava se vjerojatnost korištenja pojedinog moda prijevoza (μ je parametar koji je potrebno utvrditi istraživanjem, a u ovom slučaju iznosi -1)

$$P_1 = \frac{e^{\mu \cdot V_1}}{\sum_j e^{\mu \cdot V_{jn}}} = \frac{e^{-1 \cdot 3,80}}{e^{-1 \cdot 3,80} + e^{-1 \cdot 4,20} + e^{-1 \cdot 3,02}} = 0,260 \quad (25)$$

$$P_2 = \frac{e^{\mu \cdot V_2}}{\sum_j e^{\mu \cdot V_{jn}}} = \frac{e^{-1 \cdot 4,20}}{e^{-1 \cdot 3,80} + e^{-1 \cdot 4,20} + e^{-1 \cdot 3,02}} = 0,174 \quad (26)$$

$$P_3 = \frac{e^{\mu \cdot V_3}}{\sum_j e^{\mu \cdot V_{jn}}} = \frac{e^{-1 \cdot 3,02}}{e^{-1 \cdot 3,80} + e^{-1 \cdot 4,20} + e^{-1 \cdot 3,02}} = 0,566 \quad (27)$$

Raspodjela putovanja:

$$N_1 = N_{\text{put}} \cdot P_1 = 2000 \cdot 0,260 = 519 \text{ putovanja} \quad (28)$$

$$N_2 = N_{\text{put}} \cdot P_2 = 2000 \cdot 0,174 = 348 \text{ putovanja} \quad (29)$$

$$N_3 = N_{\text{put}} \cdot P_3 = 2000 \cdot 0,566 = 1133 \text{ putovanja} \quad (30)$$

3.6. Podmodel asignacije putovanja na prometnu mrežu

U završnom koraku klasičnog četverostupanjskog prometnog modela dolazi do spajanja prijevozne potražnje, koja je utvrđena u prethodnim koracima i prijevozne ponude. Prijevozna ponuda prometne mreže uključuje linkove i čvorove s njihovim odgovarajućim troškovima, koji proizlaze iz njihovih atributa (propusna moć, brzina, duljina). U slučajevima kada je između izvorišta i odredišta više ruta putovanja, potrebno je odabrati onu s najmanjim generaliziranim troškovima putovanja. Ruta predstavlja skup linkova između izvorišta i odredišta. Osnovno je načelo da putnik nastoji minimizirati svoje troškove putovanja.

Nakon dodjeljivanja putovanja na mrežu utvrđuje se ukupni broj putovanja na linku, a ne broj vozila na linku. Prije korištenja metoda za dodjeljivanje putovanja osobnim automobilom na mrežu, potrebno je elemente **OD** matrice podijeliti s prosječnim brojem putnika u automobilu.

Podmodel dodjeljivanja putovanja ima pet funkcija u prometnom planiranju:

1. Detaljan uvid u karakteristike prometne mreže (nedovoljna propusna moć ili nedostatak linka);
2. Prometno prognoziranje – analiza postojećeg stanja i budućih scenarija;
3. Izračun izvedbenih funkcija – razina buke, potrošnja energije, emisije štetnih tvari i stakleničkih plinova;
4. Određivanje ulaznih podataka za projektiranje prometne mreže;
5. Određivanje kalibracijskih podataka. [1]

Neophodni ulazni podaci za provođenje dodjeljivanja putovanja na mrežu su:

- **OD** matrica putovanja između zona;
- Izrađena prometna mreža;
- Značajke pojedinih elemenata (linkovi i čvorovi);
- Model odabira rute putovanja.

Izlazni podaci nakon provođenja dodjeljivanja putovanja su:

- Rute putovanja i njihove značajke;
- Prometno opterećenje ruta, linkova i čvorova.

3.6.1. Metode dodjeljivanja putovanja na mrežu

Tijekom vremena razvilo se nekoliko metoda za dodjelu **OD** matrice putovanja na prometnu mrežu i stvaranje prometnih opterećenja na linkovima. Osnovna pretpostavka u dodjeljivanju putovanja na mrežu je pretpostavka racionalnog putnika, koji do odredišta odabire rutu za koju percipira najmanje generalizirane troškove.

Svim metodama za dodjeljivanje putovanja zajedničko je:

- Potrebno je identificirati nekoliko ruta koje bi mogle biti interesantne za vozača, rute se spremaju u „stablo“;
- Potrebno je dodijeliti određeni postotak **OD** matrice putovanja na prometnice;
- Potrebno je postići konvergenciju, odnosno provesti niz iterativnih postupaka dok se ne dođe do stabilne situacije u kojoj svi putuju optimalnom rutom (npr. Wardropov ekvilibrijem).

3.6.1.1. Metoda dodjeljivanja putovanja „sve ili ništa“

Metoda dodjeljivanja putovanja „sve ili ništa“ je najjednostavnija jer pretpostavlja da na promatranoj mreži nema prometnih zagušenja i da svi vozači jednako uočavaju troškove putovanja na različitim rutama između izvorišta i odredišta putovanja. Izostanak prometnog zagušenja znači da su generalizirani troškovi linkova fiksni. Prometno opterećenje dodjeljuje se na linkove ne uzimajući u obzir njihovu propusnu moć i trenutačnu zagušenost. Koristi se samo na nezagušenoj mreži gdje postoji mali broj varijantnih ruta. Glavni nedostatak je visoka razina nestabilnosti, jer već male promjene u prometnoj mreži, mogu izazvati velike promjene u opterećenju linkova. [1]

3.6.1.2. Stohastička metoda dodjeljivanja putovanja

Temelji se na promjenjivosti uočavanja troškova putovanja. Mora uzeti u obzir sve rute putovanja između izvorišta i odredišta. Istakle su se simulacijska i proporcionalna metoda. Simulacijska metoda koristi ideje iz Monte Carlo simulacijske metode unoseći promjenjivost vozačeva uočavanja troškova. Predstavlja velik broj računalnih algoritama koji se temelje na ponavljanju slučajnog uzorka kako bi se odredili numerički rezultati. Proporcionalna metoda smješta prometne tokove na varijantne rute proporcionalno rezultatima utvrđenim korištenjem Logit metode opisane u poglavljima 3.5.1.1. Binarni Logit model i 3.5.1.2. Multinomijalni Logit model. [1]

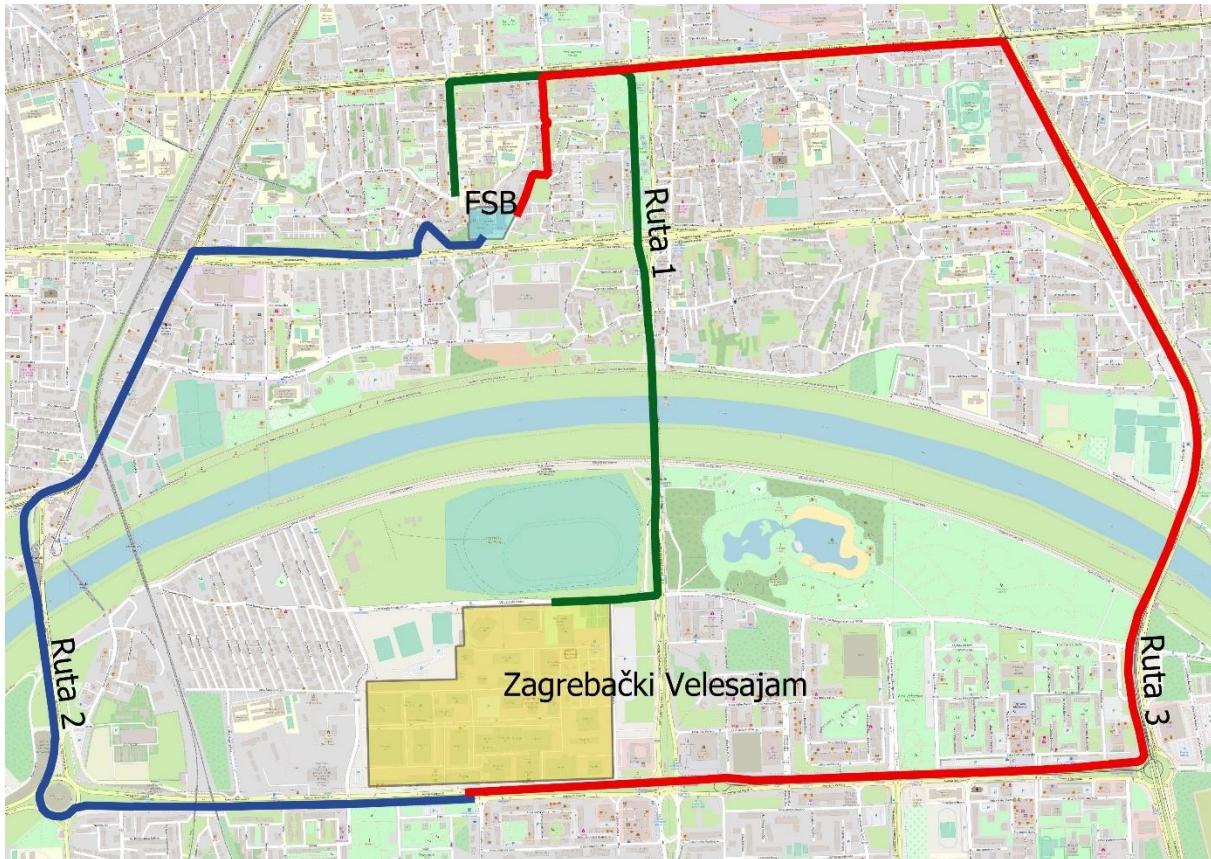
3.6.1.3. Ekvilibrijalna metoda dodjeljivanja putovanja

Najjednostavniji način opisa ekvilibrija (ravnoteže na prometnoj mreži), je da na cestovnoj mreži putnici iz fiksne **OD** matrice traže rute kako bi troškove sveli na minimum. To dovodi do isprobavanja varijantnih ruta, istraživanja novih te potom stabiliziranja u jednoj ruti nakon mnoštva pokušaja i pogrešaka. Kaže se da je ekvilibrij postignut kada putnici ne mogu naći troškovno povoljniju rutu između izvorišta i odredišta od one koju trenutno koriste. Najčešće se koristi u slučajevima zagušene prometne mreže u urbanim sredinama, a temelji se na ograničenom kapacitetu linkova prometne mreže te na funkciji trošak – prometni tok.

Predstavio ju je J. G. Wardrop, 1952 godine u radu „*Some Theoretical Aspects of Road Traffic Research*“ [17] i temelji se na Wardropovom prvom principu koji glasi: „U uvjetima ekvilibrija promet se raspoređuje po linkovima zagušene prometne mreže tako da sve iskorištene rute između **OD** parova imaju iste minimalne troškove, dok neiskorištene rute imaju veće ili iste troškove.“ U primjeru 5. je izračun broja putovanja na mreži koristeći ekvilibrijalnu metodu.

Primjer 5.[13]

Koristeći ekvilibrijelnu metodu dodjeljivanja putovanja na mrežu potrebno je izvršiti raspodjelu prometnog opterećenja od Fakulteta strojarstva i brodogradnje (FSB) do Zagrebačkog Velesajma. Ukupno prometno opterećenje koje je potrebno raspodijeliti iznosi 38 vozila. Moguće rute putovanja nalaze se na slici 13. Vrijeme putovanja izraženo je kao funkcija prometnog opterećenja. Vrijeme putovanja za rutu 1 (zeleno) je $t_1(q_1) = 8 + 2q_1$, vrijeme putovanja za rutu 2 (plava) je $t_2(q_2) = 12 + q_2$, a vrijeme putovanja za rutu 3 (crvena) je $t_3(q_3) = 38 + q_3$.



Slika 13. Moguće rute putovanja

Provodi se minimiziranje funkcije cilja $z(q)$ (jednadžba (31)) uz ograničenja jednakosti (jednadžba (32)) i ograničenja nejednakosti (jednadžba (33))

Potrebno je minimizirati funkciju cilja $z(q)$:

$$z(q) = \int_0^{q_1} (8 + 2q_1) dq_1 + \int_0^{q_2} (12 + q_2) dq_2 + \int_0^{q_3} (38 + q_3) dq_3 \quad (31)$$

Uz ograničenja:

$$q_1 + q_2 + q_3 = 38 \quad (32)$$

$$q_1, q_2, q_3 \geq 0 \quad (33)$$

Nakon integriranja jednadžbe (31) funkcija $z(q)$ poprima oblik:

$$\begin{aligned} z(q) &= 8q_1 + 2\frac{q_1^2}{2} + 12q_2 + \frac{q_2^2}{2} + 38q_3 + \frac{q_3^2}{2} \\ z(q) &= 8q_1 + q_1^2 + 12q_2 + \frac{q_2^2}{2} + 38q_3 + \frac{q_3^2}{2} \end{aligned} \quad (34)$$

Kako bi se jednadžba (34) s tri nepoznanice, reducirala na dvije nepoznanice iz uvjeta da ukupno prometno opterećenje iznosi 38 vozila određuje se:

$$\begin{aligned} q_1 + q_2 + q_3 &= 38 \\ q_1 &= 38 - q_2 - q_3 \end{aligned} \quad (35)$$

Nakon uvrštavanja jednadžbe (35) u (34), jednadžba (34) glasi:

$$\begin{aligned} z(q) &= 8(38 - q_2 - q_3) + (38 - q_2 - q_3)^2 + 12q_2 + \frac{q_2^2}{2} + 38q_3 + \frac{q_3^2}{2} \\ z(q) &= \frac{3}{2}q_2^2 + 2q_2q_3 - 72q_2 + \frac{3}{2}q_3^2 - 46q_3 + 1748 \end{aligned} \quad (36)$$

Kako bi se pronašao minimum funkcije potrebno je jednadžbu (36) parcijalno derivirati po q_2 i q_3 i parcijalne derivacije izjednačiti s 0:

$$\begin{aligned} \frac{\partial z}{\partial q_2} &= 0; \frac{\partial z}{\partial q_2} = 3q_2 + 2q_3 - 72 = 0 \\ \frac{\partial z}{\partial q_3} &= 0; \frac{\partial z}{\partial q_3} = 2q_2 + 3q_3 - 46 = 0 \end{aligned} \quad (37)$$

Nakon rješavanja sustava jednadžbi (37) određuje se:

$$q_2 = 24,8; q_3 = -1,2 \quad (38)$$

Broj putovanja na prometnici ne može biti negativan stoga se za vrijednost q_3 uzima 0. Potrebno je u jednadžbu (37) uvrstiti vrijednost $q_3 = 0$ kako bi se utvrdio stvaran broj vozila q_2 .

$$\begin{aligned} \frac{\partial z}{\partial q_2} &= 3q_2 + 2q_3 - 72 = 0 \\ \frac{\partial z}{\partial q_2} &= 3q_2 - 72 = 0 \\ q_2 &= 24 \text{ vozila} \end{aligned} \quad (39)$$

Iz jednadžbe (35) računa se q_1 i iznosi 14 vozila.

Kada se izračuna vrijeme na pojedinačnoj ruti određuje se:

$$\begin{aligned} t_1(q_1) &= 8 + 2q_1 = 8 + 2 \cdot 14 = 36 \text{ min} \\ t_2(q_2) &= 12 + q_2 = 12 + 24 = 36 \text{ min} \\ t_3(q_3) &= 38 + q_3 = 38 + 0 = 38 \text{ min} \end{aligned} \quad (40)$$

U potpunosti je zadovoljen prvi Wardropov princip jer iskorištene rute imaju jednako (minimalno) vrijeme putovanja, dok neiskorištena ruta ima veće vrijeme putovanja.

U programu *MATLAB* napravljena je provjera rješenja. Ulazni kod prikazan je na slici 14., a rješenja na slici 15. Rješenja su istovjetna onima određenim postupkom minimizacije funkcije cilja.

```
% Primjer 5.
% min f = 8*q1 + q1^2 + 12*q2 + 0.5*q2^2 + 38*q3 + 0.5*q3^2
% uz ograničenja: q1 + q2 + q3 = 38, q1, q2, q3 >= 0
% Funkcija cilja, q1 = x(1), q2 = x(2), q3 = x(3)
f = @(x) (8*x(1) + x(1).^2 + 12*x(2) + 0.5*x(2).^2 + 38*x(3) + 0.5*x(3).^2);
% Ograničenja tipa nejednakosti A*x <= b
A = []; b = [];
% Ograničenja na područje pretrage -> tražimo pozitivna rješenja
lb = [0; 0; 0]; ub = [Inf; Inf; Inf];
% Ograničenja tipa jednakosti Aeq*x = beq
Aeq = [1 1 1]; Beq = [38];
% Rješavanje pomoću fmincon funkcije
X = fmincon(f, [15 15 8], A, b, Aeq, Beq, lb, ub);
% Ispis rješenja
q1 = X(1), q2 = X(2), q3 = X(3)
```

Slika 14. Kod u *MATLABU*

q1 =	q2 =	q3 =
14.0000	24.0000	2.4934e-06

Slika 15. Rješenja primjera 5. u *MATLABU*

3.6.1.4. Dinamička metoda dodjeljivanja putovanja

Statičke metode dodjeljivanja putovanja pretpostavljaju da su prijevozna potražnja i ponuda vremenski neovisne i stalne u razdoblju. Dinamički modeli koriste realističniju pretpostavku da su ponuda, potražnja i značajke linkova varijabilni u promatranom vremenu.

Dinamičko ekvilibrijelno dodjeljivanje putovanja koristi se za velike prometne mreže (stotine zona, tisuće linkova i čvorova), a posebno je prikladno za korištenje u sljedećim situacijama:


- Simuliranje izrazito zagušenih gradskih prometnih mreža;
- Simuliranje prometnih mreža u kojima se primjenjuje dinamičko upravljanje prometnim tokovima;
- Simuliranje incidentnih događaja i planova evakuacije. [1]

4. STRUKTURA VOZNOG PARKA

Struktura voznog parka definira se prema kategorijama vozila, pogonskom gorivu i Euro emisijskim razredima. Kategorije vozila mogu biti putnički automobili, laka i teška teretna vozila, autobusi ili motocikli, dok su pogonska goriva benzin i dizelsko gorivo.

4.1. Struktura voznog parka po kategorijama vozila

U programu *COPERT: Street Level* ponuđena je struktura vozila na slici 15. Zbog nepoznavanja strukture voznog parka, pretpostavit će se struktura sa 100 % automobila kategorije M1 i N1, odnosno da je prometni tok homogen.



Slika 16. Osnovna (default) struktura voznog parka po kategorijama vozila u CSL

4.2. Passenger Car Units

Ukupni prometni tok nije homogen (kao u ovom slučaju) i sastoji se od vozila različitih vrsta, a njihov relativni sastav varira od mjesta do mjesta. Programi za izračunavanje emisija iz motornih vozila koriste zajedničku mjernu jedinicu, poznatu kao PCU (*Passenger Car Unit*) koja predstavlja opću mjeru za količinu prometa. Kategorijama vozila dodjeljuje se faktori kako bi se ukupan broj vozila sveo u jedinicu PCU. PCU vrijednosti za vrste vozila pretpostavka su autora i potrebno je provesti istraživanja i kalibraciju kako bi se predložene vrijednosti provjerile. [1] PCU vrijednosti koje se koriste za različite tipove vozila prikazane su u tablici 11.

Tablica 11. Predložene PCU vrijednosti za pojedine kategorije vozila


	Motocikli L	Putnički automobili M1	Laka teretna vozila N1 N2	Teška teretna vozila N3	Autobusi M2 M3
PCU	0,5	1	2	6	6

4.3. Struktura vozila prema pogonskom gorivu

Podaci o strukturi voznog parka osobnih automobila prema pogonskom gorivu. Podaci su dobiveni od Centar za vozila Hrvatske, Capraška 6, 10 000, Zagreb, a odnose se na vozila koja su na dan 31. prosinca 2017. imala valjan redoviti tehnički pregled, čiji je vlasnik evidentiran s prebivalištem Ozlju. Broj vozila i njihov udio prema pogonskom gorivu nalazi se u tablici 12. U Republici Hrvatskoj je 50 % vozila pogonjeno benzinom dok je u Ozlju taj broj nešto manji i iznosi 34 %. Dizelskim gorivom pogonjeno je 63 % vozila, dok je u Republici Hrvatskoj taj postotak nešto manji i iznosi 46 %.

Tablica 12. Broj vozila prema pogonskom gorivu

Vrsta pogonskog goriva	Benzin	Dizelsko gorivo	LPG
Broj automobila	293 (34,03 %)	544 (63,18 %)	24 (2,79 %)




Slika 17. Struktura putničkih automobila po pogonskom gorivu

4.4. Struktura vozila po Euro emisijskim razredima


Poznata je struktura osobnih automobila po Euro emisijskim razredima, dobivena od Centra za vozila Hrvatske, prikazana je u tablici 13. Prema pogonskom gorivu najzastupljenije je dizelsko gorivo s 544 automobila, a prema emisijskom razredu najzastupljeniji je Euro 4 razred s 247 vozila. Na slici 18. prikazan je struktura vozila prema Euro emisijskim razredima za Ozalj, a na slici 19. za Republiku Hrvatsku.

Tablica 13. Broj automobila (M1 i N1) prema Euro emisijskim razredima za grad Opatov

Vrsta goriva	Euro 1	Euro 2	Euro 3	Euro 4	Euro 5	Euro 6	Ukupno
Benzin	22	81	63	84	32	11	293
Dizelsko gorivo	31	55	119	154	153	32	544
LPG	6	4	4	9	0	1	24
Ukupno	59	140	186	247	185	44	861



Slika 18. Struktura automobila (M1 i N1) pogonjenih benzinom, dizelskim gorivom i LPG - om prema Euro emisijskim razredima za grad Opatov (2017. godina)



Slika 19. Struktura automobila (M1 i N1) pogonjenih benzinom, dizelskim gorivom i LPG - om prema Euro emisijskim razredima (Republika Hrvatska, 2016. godina)

U Ozlju i Republici Hrvatskoj najzastupljeniji emisijski razred za vozila pogonjena benzinom je *Euro 4* (Ozalj 29 %, Republika Hrvatska 30 %). Za vozila pogonjena dizelskim gorivom najzastupljeniji su emisijski razredi *Euro 3* i *4* svaki s 28 %, isto kao u Republici Hrvatskoj svaki s 29 %.

5. MODEL PROMETA U PROGRAMU *PTV VISUM*

PTV Visum je vodeći svjetski računalni program za analizu prometnih tokova, prometne prognoze i obradu u podataka GIS - u. Program *PTV VISUM* ima mogućnost modeliranja svih sudionika u prometu, njihove interakcije i svih mogućih pojava. Prometni stručnjaci koriste ga za modeliranje transportnih mreža, putničke potražnje, analizu očekivanih prometnih tokova, planiranje usluga javnog prijevoza i razvijanje naprednih prometnih strategija i rješenja. [18]



the mind of movement




Slika 20. Logo i ikona programa *PTV VISUM* [19]

Glavna svrha analitičkih modela u prometnoj analizi je omogućavanje "*what-if*" analiza. To znači izračun očekivanih posljedica u prometnom sustavu ako dođe do promjena u njemu (npr. povećanje cijene voznih karata javnog prijevoza) ili do nekih nezavisnih promjena (npr. smanjenje broja stanovništva). Svaki prometni model treba biti validiran što znači da na temelju empirijskih opažanja (npr. brojanje prometa) zadovoljavajuće opisuje ponašanje analiziranog sustava. [1]

Na izlaznim podacima programa ne nalazi se broj vozila na prometnici već broj putovanja koji se ostvaruje njome. Da bi se utvrdio broj vozila potrebno je podijeliti broj putovanja koja se odvijaju s prosječnom zauzetošću vozila. Broj putovanja se računa za jutarnji vršni sat od 7 h do 8 h, radnim danom. Cilj je napraviti seriju podataka za 24 sata u danu i 7 dana u tjednu.

5.1. Izrada modela prometa (sadašnje stanje, Case 0.X)

1. Određivanje područja za koje se želi izraditi model prometa. Modeliranje počinje postavljanjem čvorova (*Nodes*) na karti. Čvorovi označavaju poziciju raskrižja i krajnjih točaka linkova. Nakon postavljanja čvorova potrebno je odrediti njihov tip, odnosno tip raskrižja koje predstavljaju (trokut, stop, semafor, kružni tok i dr.), (slika 25).




Slika 21. Ikona Nodes u izborniku Network

2. Nakon određivanja čvorova povezuje ih se linkovima (cestama). Svakoj od prometnica potrebno je dodijeliti klasu sukladno kriterijima iz tablice 1. (slika 26.)



Slika 22. Ikona Links u izborniku Network


3. Sljedeći korak je zoniranje i određivanje centroida zona. Potrebno je podijeliti prometno područje u manje zone homogenih značajki (bolnica, vrtić, osnovna škola, trgovački centar, industrijska zona, stambeno područje i dr.) i stvoriti i ulazne i izlazne zone. Brojanjem prometa u tim zonama mogu se utvrditi ulazni podaci. Također je potrebno svakoj zoni dodijeliti određeni broj parametara koji će se koristiti za izračun. U ovom slučaju to je broj stanova, broj kuća i broj putovanja koja ulaze u /izlaze iz zona ako su krajnje zone (slika 27.).



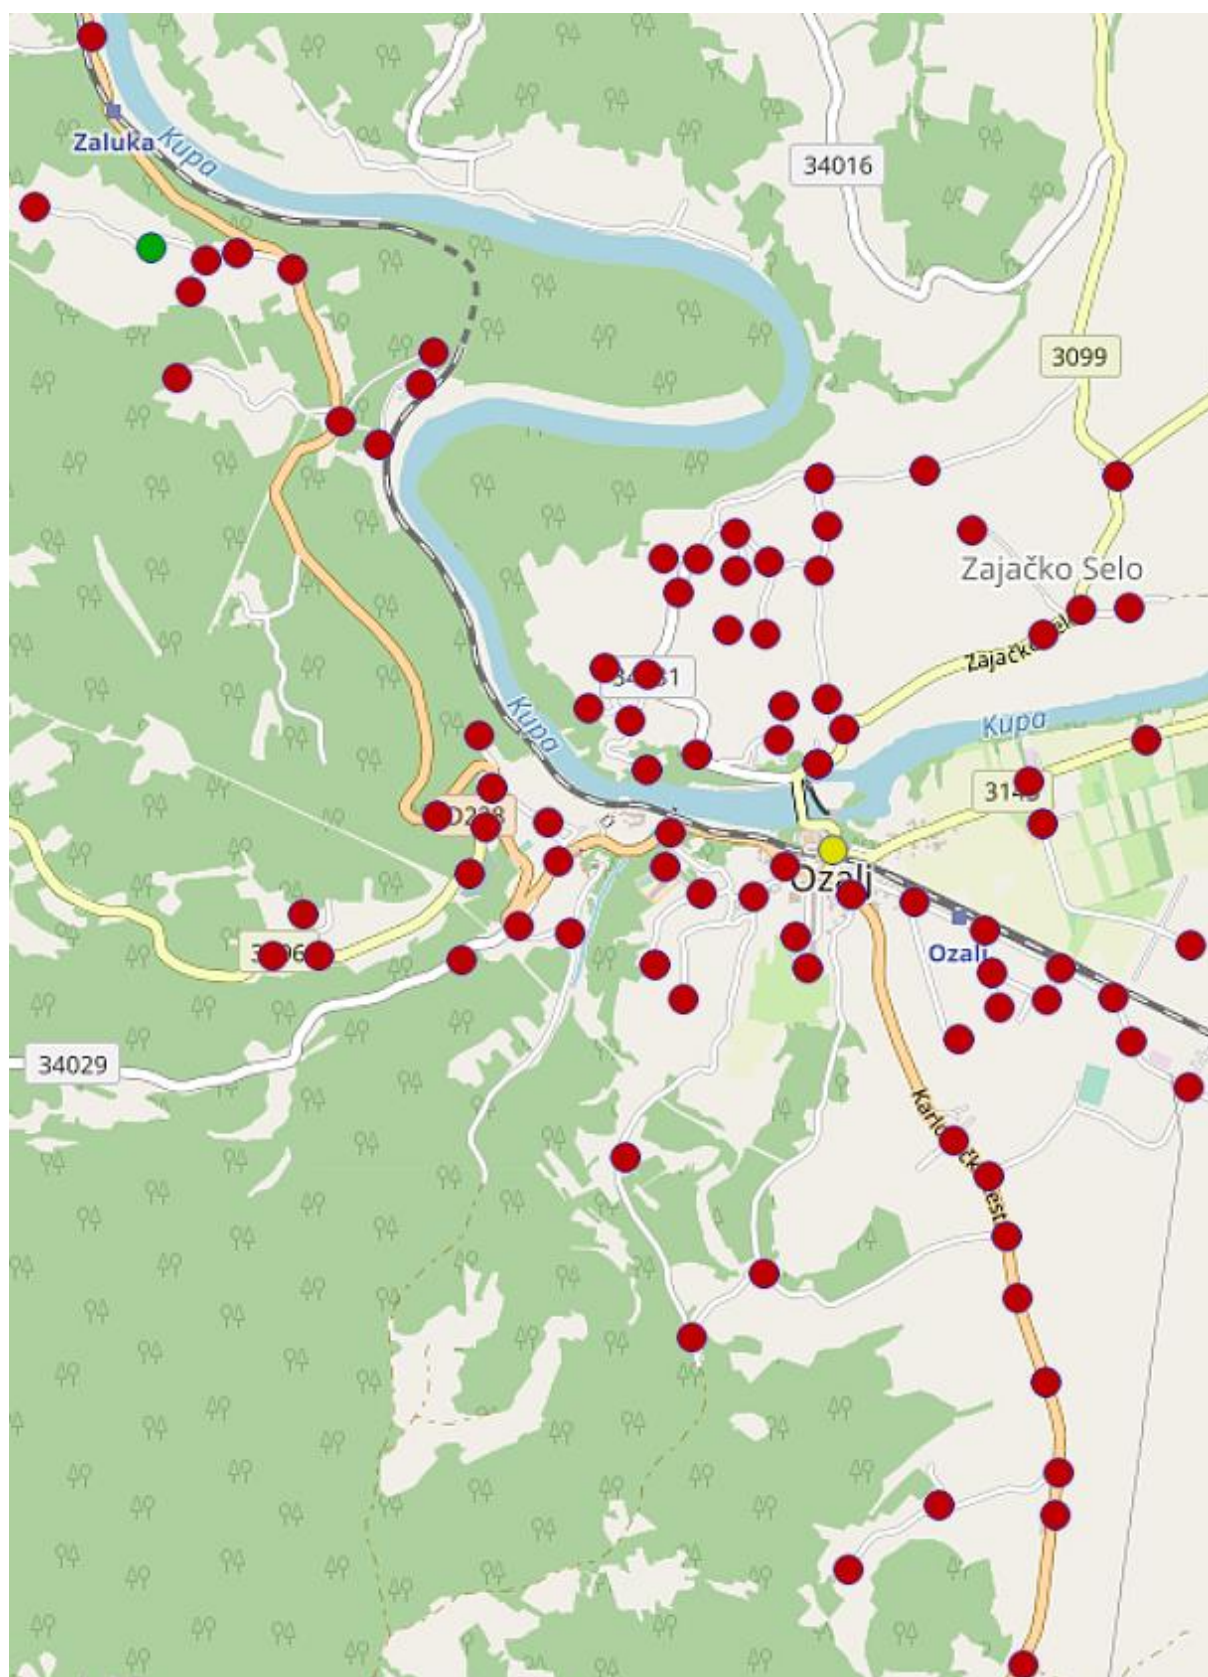
Attribute	Value
Broja_stanova	0
Broj_kuca	37
Izlaz	
Ulaz	

Slika 23. Ikona Zones u izborniku Network (lijevo) i atributi zone (desno)

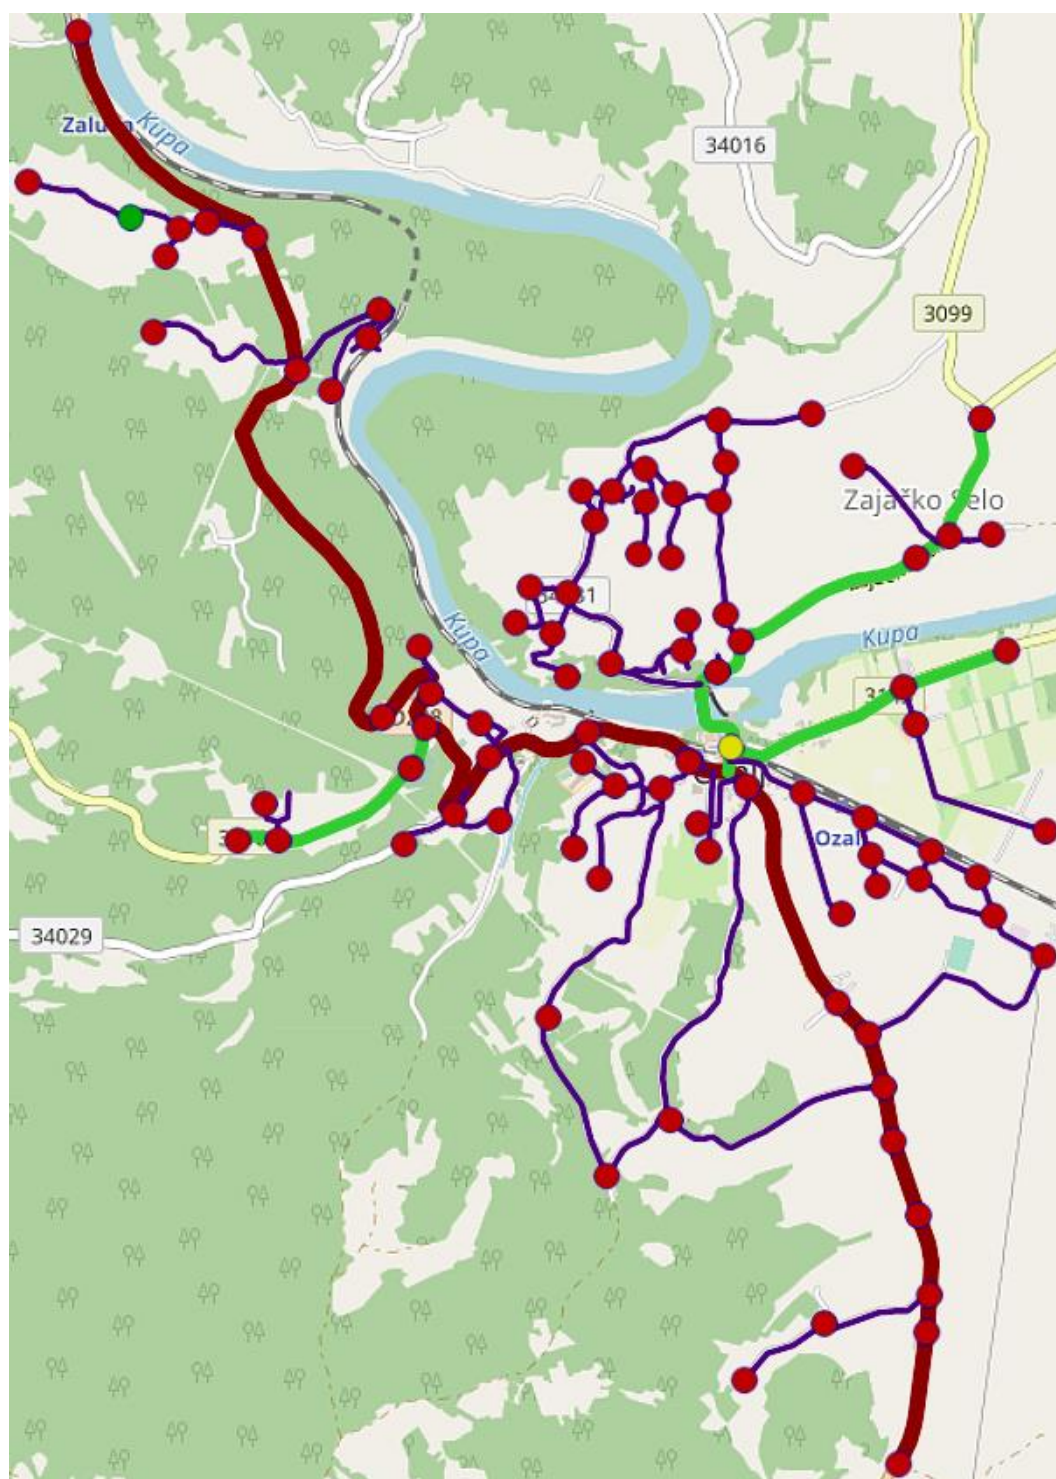
4. Svaku zonu potrebno je „konektorima“ spojiti s njenim izlaznim čvorovima kako bi se putovanja što pravilnije rasporedila na mreži (slika 28.).



Slika 24. Ikona Connectors u izborniku Network

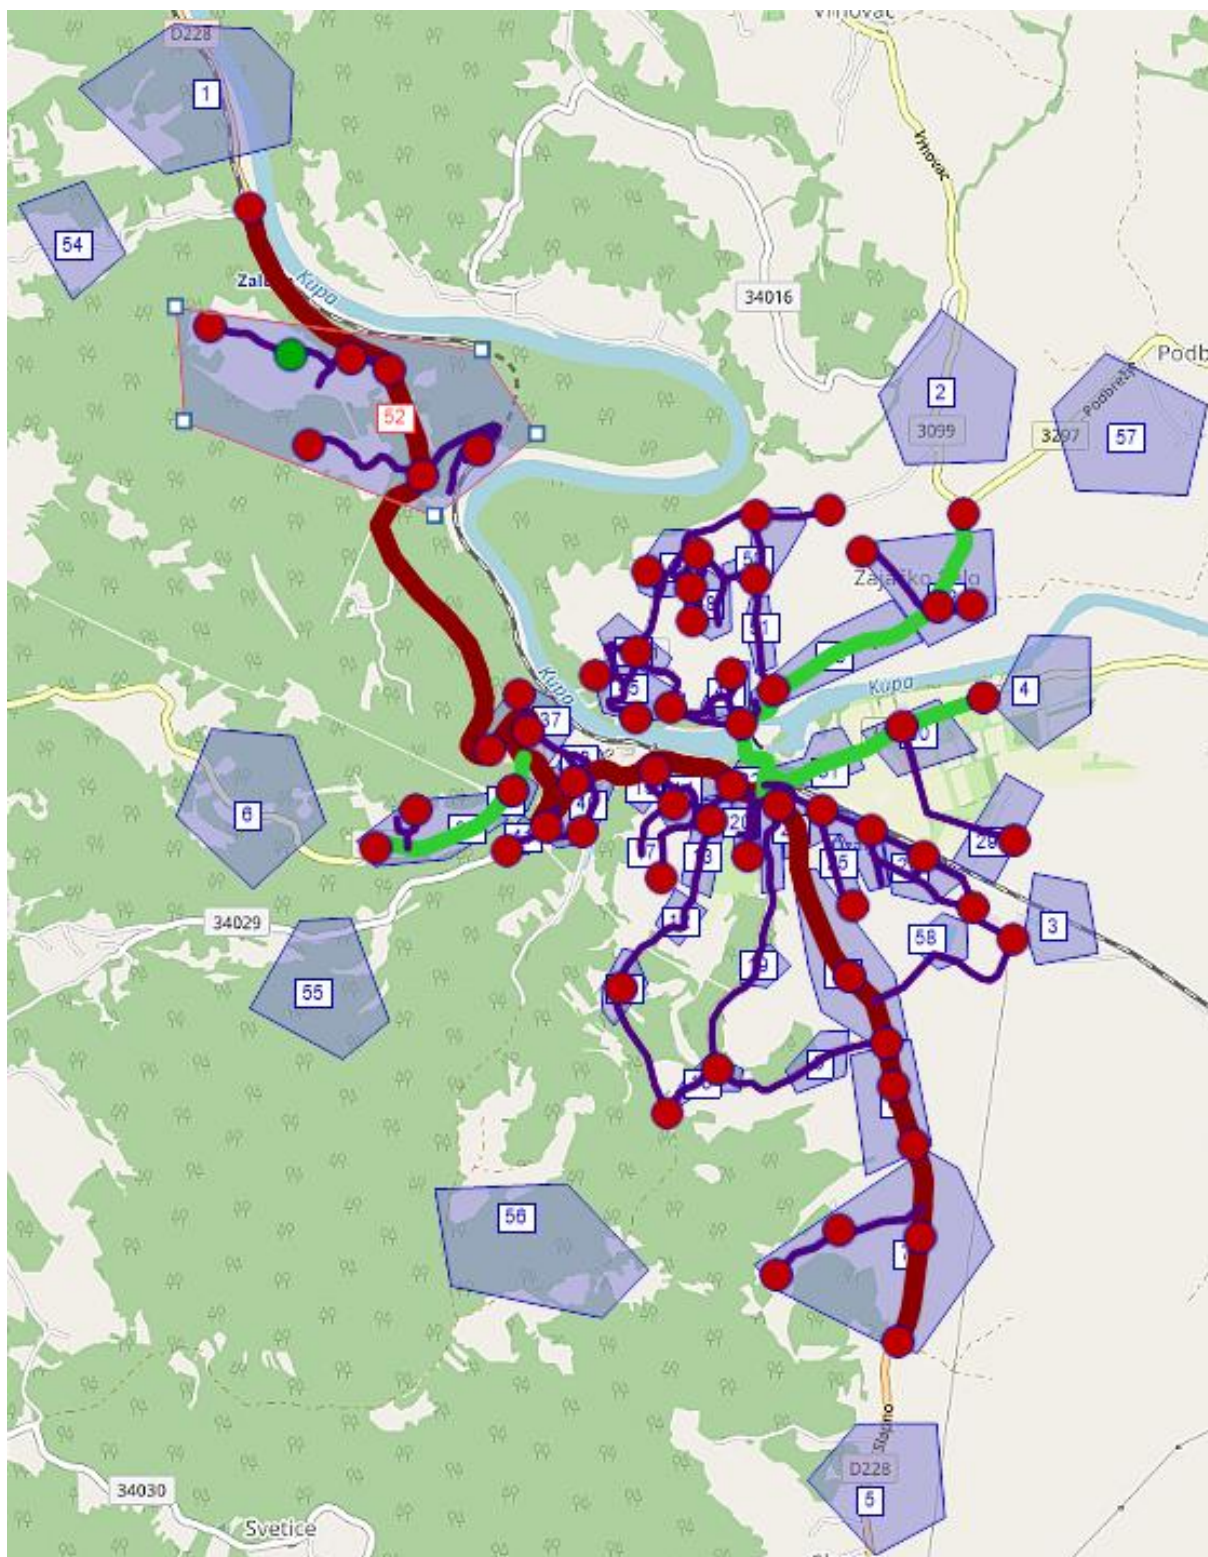


Slika 25. Raskrižja i krajnji čvorovi (1.)





Preview	LegendName	Draw	LineStyle	LineWidth	LineColor
	Autoceste	<input checked="" type="checkbox"/>		1.00	
	Brze_cesta	<input checked="" type="checkbox"/>		1.00	
	Drzavne_cesta	<input checked="" type="checkbox"/>		2.50	
	Lokalne_cesta	<input checked="" type="checkbox"/>		2.00	
	Nerazvrstane_cesta	<input checked="" type="checkbox"/>		1.00	

Slika 26. Linkovi i legenda (2.)



Slika 27. Zone (3.)



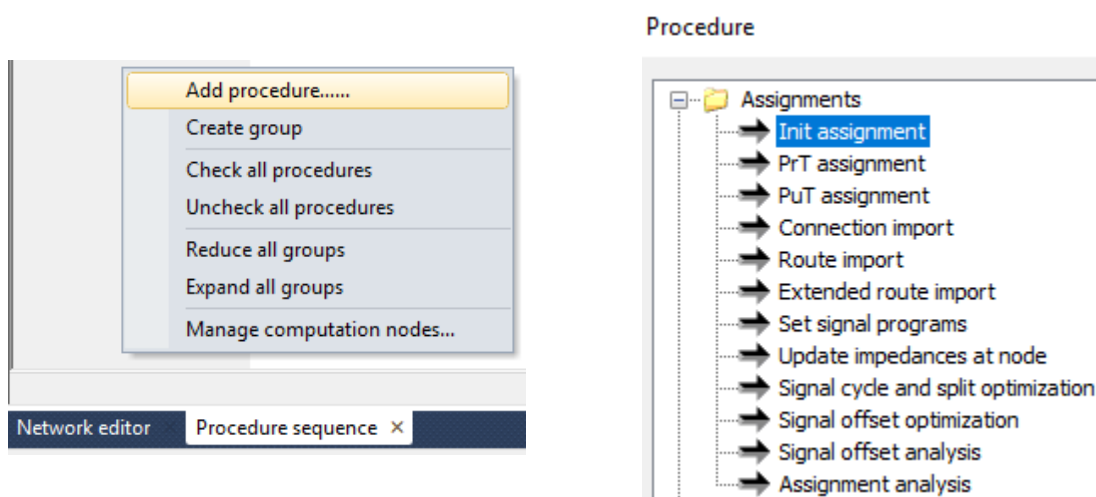
Slika 28. Konektori (4.)

5. 0. korak (*Initial assignment*)

Nakon što su svi atributi na karti dodijeljeni (raskrižja, linkovi, zone, konektori), parametri zona uneseni, počinje se provoditi klasični četverostupanjski model koji je opisan u poglavlju 3. Klasični četverostupanjski model prometne potražnje.

Potrebno je dodati 0. korak modela, brisanje svih rezultata i podataka prošlih simulacija kako bi se nova simulacija provela neovisno o njima, odnosno kako ne bi došlo do kolizije i pogrešnog „čitanja“ podataka iz memorije.

Procedura započinje tako da u izborniku *Procedure sequence* i nakon toga *Add procedure*. U padajućem izborniku *Assignments* odabire se *Init Assignment* (slika 29.).



Slika 29. Dodavanje Initial Assignmenta u proceduru

Nakon dodavanja procedure na listi procedura dodaje se *Init assignment* (slika 30.).

Number: 1	Execution	Active	Procedure	Reference object(s)	Variant/file
1		<input checked="" type="checkbox"/>	Init assignment		All

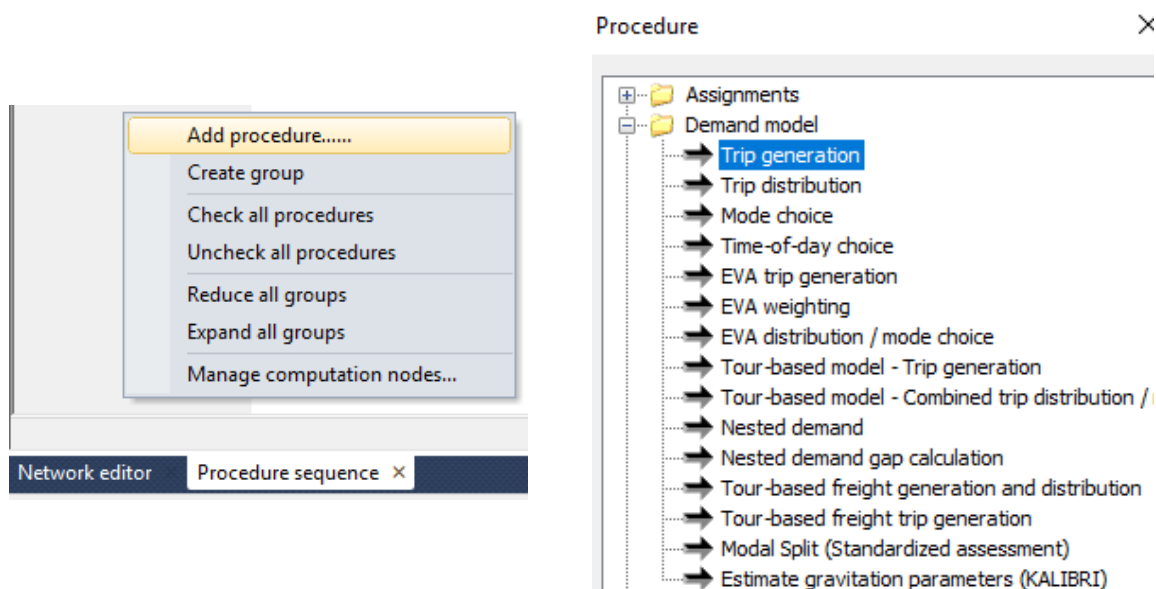
Slika 30. Koraci procedure nakon dodavanja Initial assignmenta

6. 1. korak – Podmodel generiranja putovanja (*Trip generation*)

Idući korak je stvaranje procedure za izračun ukupnog broja putovanja koje se generira u određenoj zoni i koji određena zona privlači.

U izborniku se odabire *Procedure sequence* i nakon toga *Add procedure* (slika 31.).

U padajućem izborniku *Demand model* odabire se *Trip generation*



Slika 31. Dodavanje *Trip generation* u proceduru

Nakon dodavanja procedure na listi procedura dodaje se *Trip generation* (slika 32.).

Number: 2	Execution	Active	Procedure	Reference object(s)	Variant/file
1	▶	<input checked="" type="checkbox"/>	Init assignment		All
2		<input checked="" type="checkbox"/>	Trip generation	Sve_Svi	

Slika 32. Koraci procedure nakon dodavanja *Trip generation*a

Potrebno je unijeti funkcije produkcije i atrakcije prema kojima će se računati broj putovanja koja zona generira i privlači. Izjednačavanje broja generiranih i privučenih putovanja izvodi se prema produkciji putovanja po zonama, jer su modeli za procjenu produkcije putovanja točniji od onih za atrakciju putovanja. Vrijednosti produkcije ostaju konstantne, a vrijednosti atrakcije prilagođavaju se kako bi njihov zbroj odgovarao zbroju produkcije svih zona. Podaci o produkciji uzimaju se iz priručnika ITE *Trip Generation* [14], a funkcije vrijednosti za kuće i stanove su prikazane na slikama 10. i 11.

	Demand stratum	Matrix balancing	Production function	Attraction function
1	Sve_Svi	Production total	$[BROJ_KUCA]*0.56+[BROJA_STANOVA]*0.4+[IZLAZ]*1.3 \dots$	$[BROJ_KUCA]*0.18+[BROJA_STANOVA]*0.11+[ULAZ]*1.3 \dots$

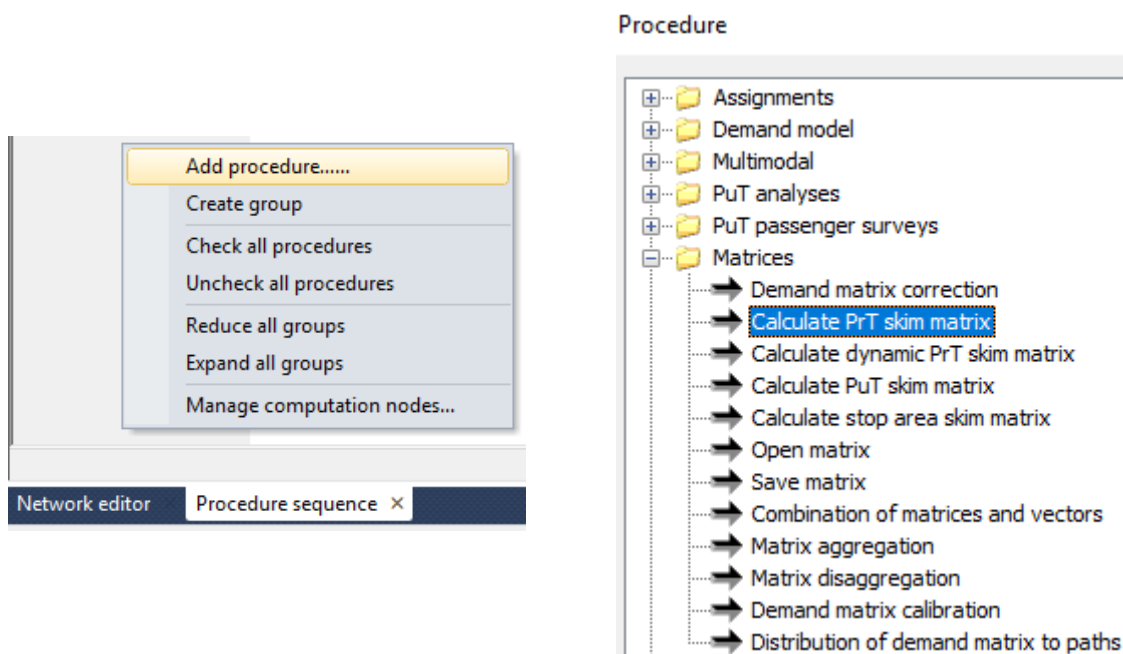
Slika 33. Funkcije produkcije i atrakcije

7. 2. korak – Izračun matrice distribucije putovanja (*Calcualte PrT skim matrix*)

Nakon zadavanja funkcija za produkcija i atrakciju zona, potrebno je izračunati *Skim* matricu u kojoj se nalazi impedancija (otpori putovanju) između zona.

U izborniku se odabire *Procedure sequence* i nakon toga *Add procedure* (slika 34.).

U padajućem izborniku *Matrices* odabire se *Calcualte PrT skim matrix*.



Slika 34. Dodavanje *Calculate PrT skim matrix* u proceduru

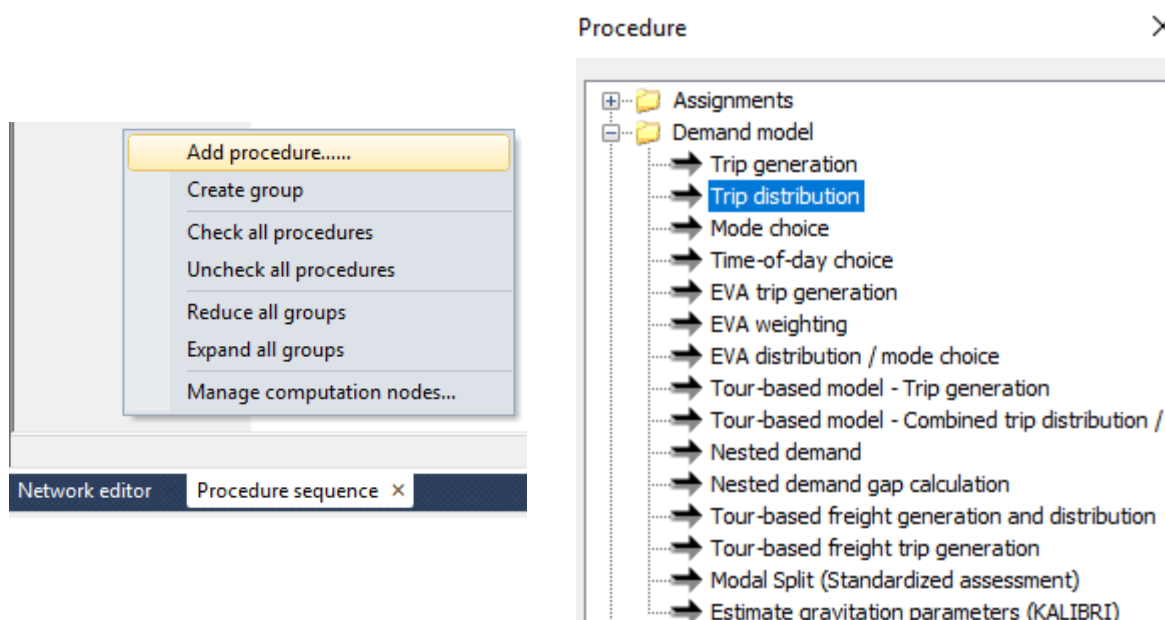
Nakon dodavanja procedure na listi procedura dodaje se *Calcualte PrT skim matrix* (slika 35.).

Number: 3	Execution	Active	Procedure	Reference object(s)	Variant/file
1	▶	<input checked="" type="checkbox"/>	Init assignment		All
2		<input checked="" type="checkbox"/>	Trip generation	Sve_Svi	
3		<input checked="" type="checkbox"/>	Calculate PrT skim matrix	C Car	

Slika 35. Koraci procedure nakon dodavanja *Calculate PrT skim matrix*

8. 3. korak – Podmodel distribucije putovanja (*Trip distribution*)

Sljedeći korak je izračun distribucije putovanja, odnosno raspodjela putovanja između zona. U izborniku se odabire *Procedure sequence* i nakon toga *Add procedure* (slika 36.). U padajućem izborniku *Demand model* odabire se *Trip distribution*.



Slika 36. Dodavanje *Trip distribution* u proceduru

Koristi se distribucijska funkcija istovjetna jednadžbi (9), a za generaliziranu distribucijsku funkciju putovanja $f(c_{ij})$ koristi se kombinirana (Tannerova) funkcija (jednadžba 12), s parametrima $a = 1$, $b = 0,265$, $c = -0,04$ koji su preuzeti iz *ITE Trip Generation* [14] (slika 37.).

	Demand stratum	Utility function	Function type	a	b	c	Direction parameters
1	Sve_Svi	Matrix([NO] = ...	Combined	1	0.265	-0.04	Productions, Singly constrained

Slika 37. Parametri kombinirane (Tannerove) funkcije

Nakon dodavanja procedure na listi procedura dodaje se *Trip distribution* (slika 38.).

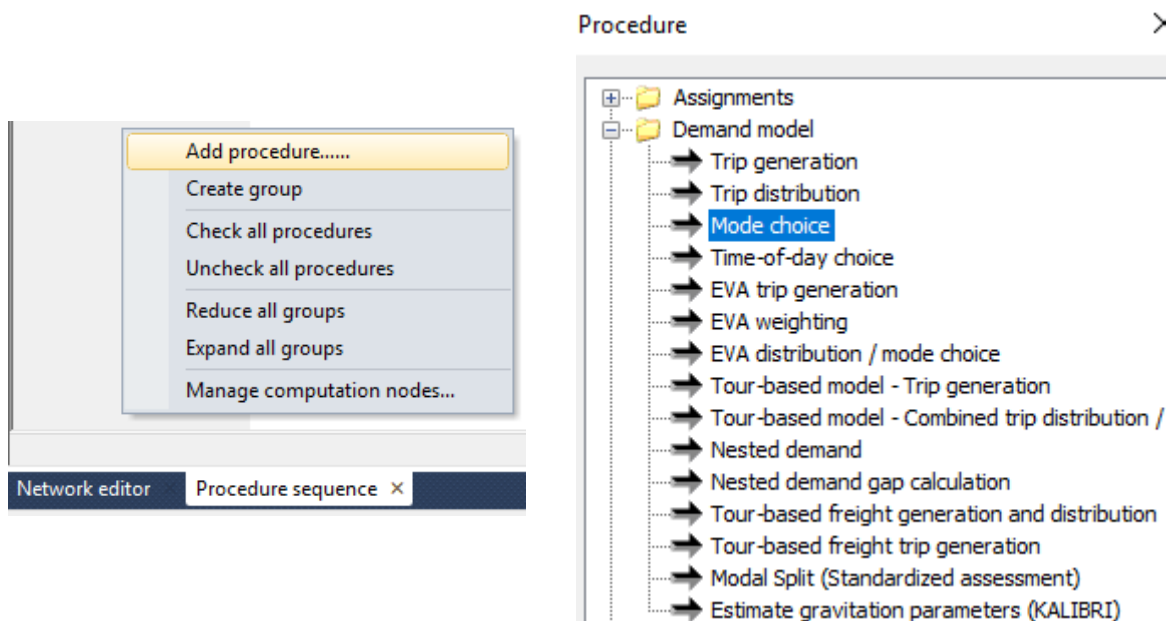
Number: 4	Execution	Active	Procedure	Reference object(s)	Variant/file
1	▶	<input checked="" type="checkbox"/>	Init assignment		All
2		<input checked="" type="checkbox"/>	Trip generation	Sve_Svi	
3		<input checked="" type="checkbox"/>	Calculate PrT skim matrix	C Car	
4		<input checked="" type="checkbox"/>	Trip distribution	Sve_Svi	

Slika 38. Koraci procedure nakon dodavanja *Trip distribution*

9. 4. korak – Modalna raspodjela putovanja (*Mode choiche*)

U modelu sadašnjeg stanja pretpostavlja se samo jedan mod (način) prijevoza, a to je osobni automobil, stoga se ovaj korak izvodi kako bi se zadovoljila procedura u programu.

U izborniku se odabire *Procedure sequence* i nakon toga *Add procedure* (slika 39.).



Slika 39. Dodavanje *Mode choichea* u proceduru

U padajućem izborniku *Demand model* odabire se *Mode choiche*. Nakon dodavanja procedure na listi procedura dodaje se *Mode choiche* (slika 40.).

Number: 5	Execution	Active	Procedure	Reference object(s)	Variant/file
1	▶	<input checked="" type="checkbox"/>	Init assignment		All
2		<input checked="" type="checkbox"/>	Trip generation	Sve_Svi	
3		<input checked="" type="checkbox"/>	Calculate PrT skim matrix	C Car	
4		<input checked="" type="checkbox"/>	Trip distribution	Sve_Svi	
5		<input checked="" type="checkbox"/>	Mode choice	Sve_Svi	

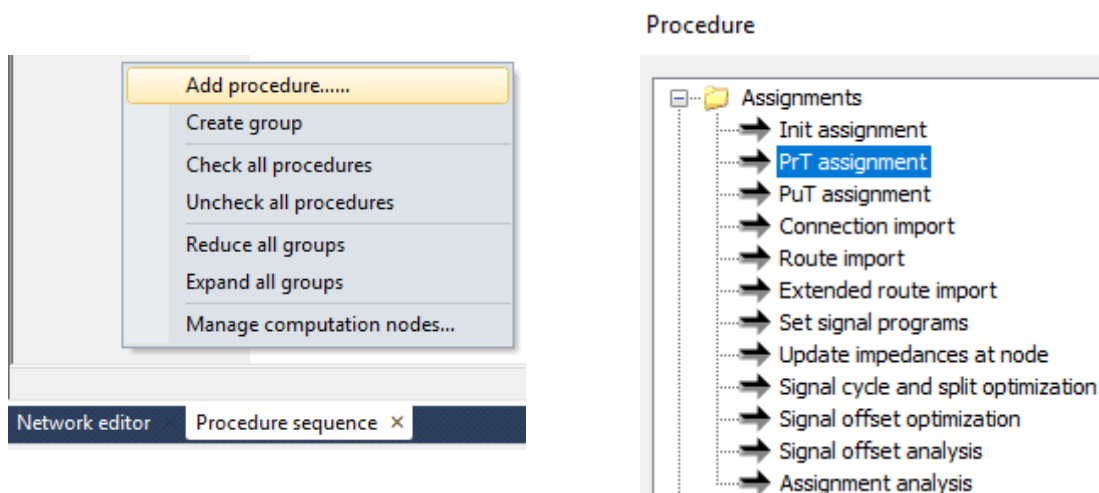
Slika 40. Koraci procedure nakon dodavanja *Mode choichea*

10. 5. korak – Dodjela (asignacija) putovanja na mrežu (*PrT assignment*)

U ovom koraku odabire se metoda kojom će se putovanja dodjeljivati na mrežu. Odabire se ekvilibrijalna metoda dodjeljivanja (*Equilibrium assignment*) opisana u poglavlju 3.6.1.3. Ekvilibrijalna metoda dodjeljivanja putovanja.

U izborniku se odabire *Procedure sequence* i nakon toga *Add procedure* (slika 41.).

U padajućem izborniku *Assignments* odabire se *PrT assignment*.



Slika 41. Dodavanje *PrT assignmenta* u proceduru

Nakon dodavanja procedure na listi procedura dodaje se *PrT assignment* (slika 42.).

Number: 6	Execution	Active	Procedure	Reference object(s)	Variant/file
1	▶	<input checked="" type="checkbox"/>	Init assignment		All
2		<input checked="" type="checkbox"/>	Trip generation	Sve_Svi	
3		<input checked="" type="checkbox"/>	Calculate PrT skim matrix	C Car	
4		<input checked="" type="checkbox"/>	Trip distribution	Sve_Svi	
5		<input checked="" type="checkbox"/>	Mode choice	Sve_Svi	
6		<input checked="" type="checkbox"/>	PrT assignment	C Car	Equilibrium assignment

Slika 42. Koraci procedure nakon dodavanja *PrT assignmenta*

11. Pokretanje procedure

Procedura se pokreće pomoću zelenog gumba *Play* u izborniku u gornjem lijevom kutu. Izvođenje svakog koraka može se pratiti i ako za korak u rubrici *Success* postoji znak ☒ korak je uspješno izveden (slika 43.).


The image shows the same table as in Slika 42, but with a red box highlighting the 'Success' column. The 'Success' column contains checkboxes for each step, all of which are checked. The first row (Step 1) is also highlighted in orange. Above the table, there is a toolbar with icons for play, stop, and other functions.

Number: 6	Execution	Active	Procedure	Reference object(s)	Variant/file	Comment	ComputeNode	Success
1	▶	<input checked="" type="checkbox"/>	Init assignment		All			<input checked="" type="checkbox"/>
2		<input checked="" type="checkbox"/>	Trip generation	Sve_Svi				<input checked="" type="checkbox"/>
3		<input checked="" type="checkbox"/>	Calculate PrT skim matrix	C Car				<input checked="" type="checkbox"/>
4		<input checked="" type="checkbox"/>	Trip distribution	Sve_Svi				<input checked="" type="checkbox"/>
5		<input checked="" type="checkbox"/>	Mode choice	Sve_Svi				<input checked="" type="checkbox"/>
6		<input checked="" type="checkbox"/>	PrT assignment	C Car	Equilibrium assignment			<input checked="" type="checkbox"/>

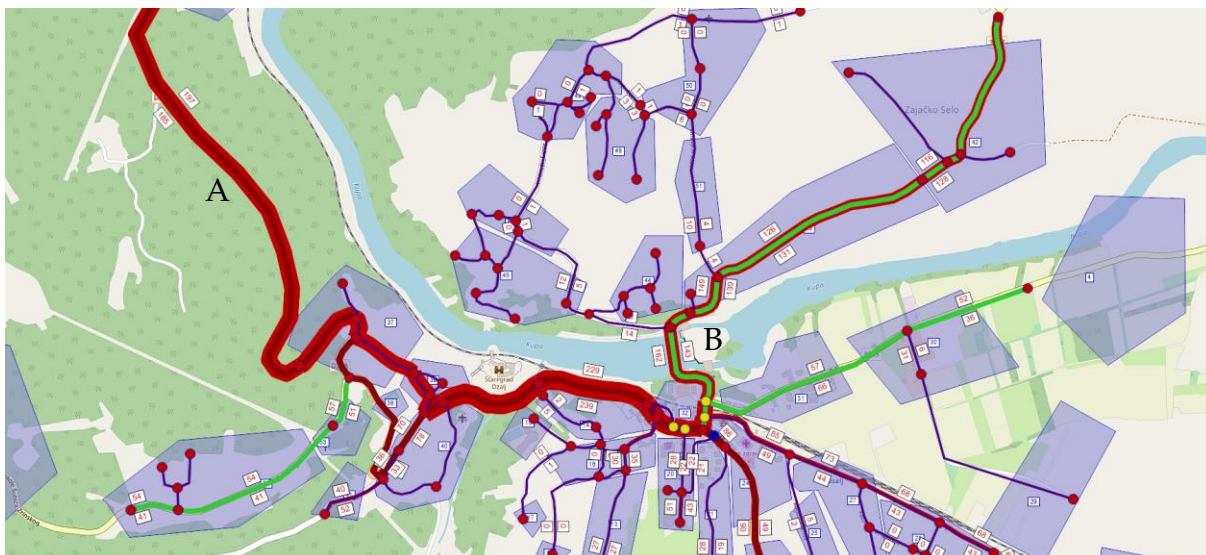
Slika 43. Svi koraci procedure uspješno izvedeni

12. Prikaz rezultata na mreži

Kada je cijela procedura izvedena, za prikaz rezultata (broja putovanja) na mreži u *Network editoru*. Prometno opterećenje linka u jutarnjem vršnom satu radnim danom prikazano je debljinom crvene linije oko prometnice na slici 44.



Slika 44. Broj putovanja za sadašnje stanje razvoja prometa za jutarnji vršni sat radnim danom



Slika 45. Broj putovanja u centru grada za sadašnje stanje razvoja prometa za jutarnji vršni sat radnim danom

Prometno najopterećenija prometnica je državna cesta D228 (granični prijelaz Jurovski Brod – Karlovac) s 382 putovanja nakon ulaznih zona, na slikama 44. i 45 označena slovom A. U jutarnjem vršnom satu putnici ju koriste za putovanja prema Karlovcu na posao. Prema Jastrebarskom i Zagrebu vodi cesta Ž3927 koja počinje od mosta preko Kupe. Most preko Kupe najopterećenija je točka u gradu s 305 putovanja u jutarnjem vršnom satu radnim danom, a na slikama 44 i 45. označen je slovom B.

Izlazne podatke moguće je prikazati i kao popis svih linkova i njihovih atributa (slika 44.). Postoji mogućnost spremanja izlaznih podataka u raznim oblicima, u ovom slučaju najkorisniji format za spremanje izlaznih podataka je .xlsx (*Excel* datoteka). Excel datoteka je ulazna datoteka u programu *COPERT: Street Level* za izračun emisija iz cestovnog prometa. Pravilnim odabirom stupaca ulaznih podataka u *COPERT: Street Levelu* značajno se pojednostavljuje izračun emisija.

Number: 308	No	FromNodeNo	ToNodeNo	TypeNo	TSysSet	Length	NumLanes	CapPrT	VOPrT	VolVehPrT(AP)
1	1	6	36	20	B,C,W	0.052km	1	1700	90km/h	210
2	1	36	6	20	B,C,W	0.052km	1	1700	90km/h	217
3	2	5	36	20	B,C,W	0.032km	1	1700	80km/h	217
4	2	36	5	20	B,C,W	0.032km	1	1700	80km/h	212
5	4	4	37	20	B,C,W	0.042km	1	1700	80km/h	122
6	4	37	4	20	B,C,W	0.042km	1	1700	80km/h	86
7	5	37	47	20	B,C,W	0.754km	1	1700	80km/h	90
8	5	47	37	20	B,C,W	0.754km	1	1700	80km/h	49
9	6	47	48	20	B,C,W	0.138km	1	1700	80km/h	90
10	6	48	47	20	B,C,W	0.138km	1	1700	80km/h	49
11	7	44	48	20	B,C,W	0.172km	1	1700	80km/h	55
12	7	48	44	20	B,C,W	0.172km	1	1700	80km/h	106
13	8	43	44	20	B,C,W	0.172km	1	1700	80km/h	41

Slika 46. Lista linkova s atributima

5.2. Definicija različitih scenarija razvoja prometa

Kao što je prije spomenuto, u slučaju planiranja objekata cestovne infrastrukture predlaže se analiza sljedeće tri varijante:

- Utjecaj na okoliš – rješavanje problema s najmanjim utjecajem na okoliš;
- Javni gradski prijevoz – poboljšanje prometne ponude javnog gradskog prijevoza;
- Izgradnja novih građevinskih elemenata prometne ponude.

Razmatraju se tri scenarija odvijanja prometa, svaki odabran kako bi prikazao neke od mogućnosti programa *PTV Visuma*. Prva znamenka kod naziva scenarija predstavlja scenarij razvoja prometa, a znamenka nakon točke predstavlja scenarij za izračun emisija.

- Scenarij 1 (1.X) – gradnja novog mosta (dodavanje novog linka u mrežu prometnica i promatranje njegovog utjecaja na raspodjelu putovanja);
- Scenarij 2 (2.X) – uvođenje linije javnog gradskog prijevoza (da se pokaže kako se i više sustava prijevoza može integrirati u jedan model prometa);
- Scenarij 3 (3.X) – upravljanje u incidentnim situacijama (prekidanje jednog linka u mreži kako bi se prikazao utjecaj raspodjele putovanja u cijeloj mreži).

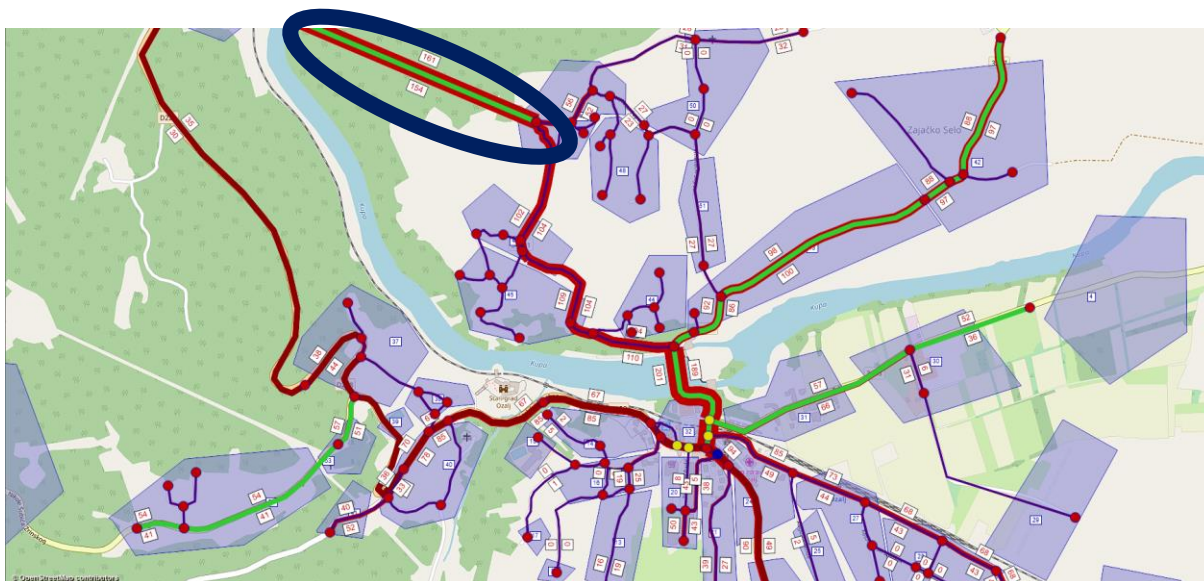
5.2.1. Scenarij 1 – gradnja novog mosta (1.X)

Trenutno je u Ozlju izgrađen samo jedan most preko Kupe (slika 47.), u blizini male hidroelektrane Ozalj i svaki prelazak rijeke odvija se preko njega.




Slika 47. Most u Ozlju [9]

U ovom scenariju će se razmatrati gradnja novog mosta uzvodno na cesti D228, 1,65 km uzvodno od sadašnjeg mosta (plavo označen na slici 48.). Raspodjela putovanja nakon izgradnje novog mosta je na slici 48.



Slika 48. Broj putovanja u centru grada nakon izgradnje novog mosta za jutarnji vršni sat radnim danom


Nakon izgradnje novog mosta njime se odvija 315 putovanja u jutarnjem vršnom satu, dok se starim mostom broj putovanja povećava i sada iznosi 390 putovanja (prije se starim mostom odvijalo 305 putovanja, povećanje od 28 %). Broj putovanj na D228 (A) nakon ulaznih zona ostaje isti, no nakon mosta se smanjuje na 65 putovanja (prije izgradnje mosta tamo se odvijalo 382 putovanja, smanjenje od 83 %). Na ovom primjeru se vidi specifičnost ekvilibrijalne metode u kojoj putnici traže rutu s minimalnim troškovima putovanja. Kako se izgradnjom novog mosta put do starog mosta skraćuje više putovanja odvija se dijelom grada koji je sjeverno od Kupe, a ne koristi se D228, jer je to duža ruta putovanja. Putovanja se počinju odvijati D228 tek kada se troškovi (vrijeme) putovanja izjednači vremenom putovanja preko novog mosta, kojim vrijeme putovanja raste zbog veće prometne potražnje. Kada se vremena putovanja rutom preko novog mosta i D228 izjednače postignut je ekvilibrij (stanje ravnoteže) prometne mreže.



Slika 49. Broj putovanja nakon izgradnje novog mosta za jutarnji vršni sat radnim danom

5.2.2. Scenarij 2 – uvođenje linije javnog gradskog prijevoza (2.X)

Uvodi se linija javnog prijevoza koja će prometovati od Ulice Nikole Šubića Zrinskog preko mosta do Ulice Zajačko selo (linija označena zeleno, a stanice slovom H na slici 50.).



Slika 50. Trasa autobusne linije

Predloženi vozni red autobusa je na slici 51., predviđa se da autobus kreće svakih 15 minuta s obje krajnje stanice.

ObjNo	ObjCode	ObjName	Arr / Dep	Arr / Dep	Arr / Dep	Arr / Dep	Arr / Dep	Arr / Dep	Arr / Dep	Arr / Dep	Arr / Dep	Arr / Dep	Arr / Dep	Arr / Dep	Arr / Dep	Arr / Dep	Arr / Dep
75			06:19:22	06:34:22	06:49:22	07:04:22	07:19:22	07:34:22	07:49:22	08:04:22	08:19:22	08:34:22	08:49:22				
158			06:19:02	06:34:02	06:49:02	07:04:02	07:19:02	07:34:02	07:49:02	08:04:02	08:19:02	08:34:02	08:49:02				
157			06:18:48	06:33:48	06:48:48	07:03:48	07:18:48	07:33:48	07:48:48	08:03:48	08:18:48	08:33:48	08:48:48				
156			06:18:00	06:33:00	06:48:00	07:03:00	07:18:00	07:33:00	07:48:00	08:03:00	08:18:00	08:33:00	08:48:00				
155			06:17:05	06:32:05	06:47:05	07:02:05	07:17:05	07:32:05	07:47:05	08:02:05	08:17:05	08:32:05	08:47:05				
154			06:16:29	06:31:29	06:46:29	07:01:29	07:16:29	07:31:29	07:46:29	08:01:29	08:16:29	08:31:29	08:46:29				
11			06:16:00	06:31:00	06:46:00	07:01:00	07:16:00	07:31:00	07:46:00	08:01:00	08:16:00	08:31:00	08:46:00				
153			06:15:25	06:30:25	06:45:25	07:00:25	07:15:25	07:30:25	07:45:25	08:00:25	08:15:25	08:30:25	08:45:25				
55			06:15:00	06:30:00	06:45:00	07:00:00	07:15:00	07:30:00	07:45:00	08:00:00	08:15:00	08:30:00	08:45:00				

Slika 51. Predviđeni vozni red autobusne linije radnim danom

U proceduri je potrebno napraviti izmjene kako bi se mogao provesti novi izračun putovanja. U *Mode choiche* potrebno je uvesti modalnu raspodjelu putovanja prema binarnoj Logit funkciji koja je opisana u poglavlju 3.5.1.1. Binarni Logit model (slika 53.).

Number: 8	Execution	Active	Procedure	Reference object(s)	Variant/file
1	▶	<input checked="" type="checkbox"/>	Init assignment		All
2		<input type="checkbox"/>	Trip generation	Sve_Svi	
3		<input type="checkbox"/>	Calculate PrT skim matrix	C Car	
4		<input type="checkbox"/>	Trip distribution	Sve_Svi	
5		<input type="checkbox"/>	Calculate PuT skim matrix	PuT PuT	Timetable-based
6		<input type="checkbox"/>	Mode choice	Sve_Svi	
7		<input type="checkbox"/>	PrT assignment	C Car	Equilibrium assignme
8		<input type="checkbox"/>	PuT assignment	PuT PuT	Timetable-based

Slika 52. Procedura za izračun putovanja nakon dodavanja autobusne linije

Parameters: Mode choice

☒ Set any result demand matrix to 0 prior to calculation

Key	Demand stratum	Mode	Utility function	Function type	a	b	c	
1 Sve_Svi/C	Sve_Svi	C Car	-0.06*Matrix([NO] = 1)-2	Logit	0	0	1.4	Matrix([DMODELCODE] =
2 Sve_Svi/PuT	Sve_Svi	PuT PuT	-0.06*Matrix([NO] = 3)-0.12*Matrix([NO] = 10)-0.12*Matrix([NO] = 11)+	Logit	0	0	1.4	Matrix([DMODELCODE] =

Slika 53. Funkcije binarnog Logit modela

Nakon što su svi parametri uneseni, ponovo se pokreće procedura i prati se hoće li se pod stupcem Success pojaviti ☒, ako se kraj svakog koraka procedure pojavi ☒, cijela procedura uspješno je izvedena (slika 54.).

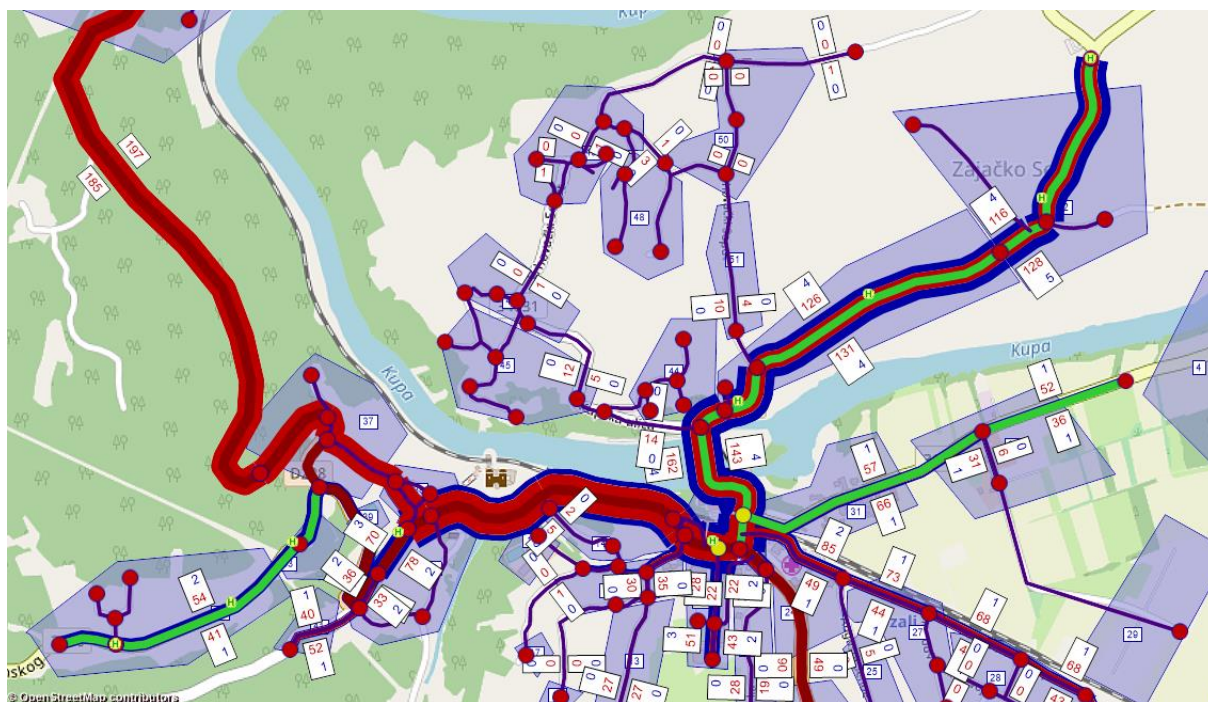
Number: 8	Execution	Active	Procedure	Reference object(s)	Variant/file	Comment	ComputeNode	Success
1	▶	<input checked="" type="checkbox"/>	Init assignment		All			<input checked="" type="checkbox"/>
2		<input checked="" type="checkbox"/>	Trip generation	Sve_Svi				<input checked="" type="checkbox"/>
3		<input checked="" type="checkbox"/>	Calculate PrT skim matrix	C Car				<input checked="" type="checkbox"/>
4		<input checked="" type="checkbox"/>	Trip distribution	Sve_Svi				<input checked="" type="checkbox"/>
5		<input checked="" type="checkbox"/>	Calculate PuT skim matrix	PuT PuT	Timetable-based			<input checked="" type="checkbox"/>
6		<input checked="" type="checkbox"/>	Mode choice	Sve_Svi				<input checked="" type="checkbox"/>
7		<input checked="" type="checkbox"/>	PrT assignment	C Car	Equilibrium assignme			<input checked="" type="checkbox"/>
8		<input checked="" type="checkbox"/>	PuT assignment	PuT PuT	Timetable-based			<input checked="" type="checkbox"/>

Slika 54. Svi koraci procedure uspješno izvedeni

Broj putovanja koji se obavi javnim gradskim prijevozom je na slici 55. (plavi broj) nalazi se iznad broja putovanja na mreži (crveni broj). Ukupan broj putovanja na mreži prije uvođenja linije javnog gradskog prijevoza na svim linkovima iznosi 13 784, a nakon njenog uvođenja broj putovanja javnim gradskim prijevozom na svim linkovima iznosi 182. Korisnost linije javnog gradskog prijevoza računa se:

$$\eta_{JGP} = \frac{n_{JGP}}{n_{UK}} = \frac{182}{13784} = 0,013 = 1,3 \% \quad (41)$$

Korisnost linije javnog gradskog prijevoza manje je od 5 % stoga dovoljna da bi se isplatilo njezino uvođenje. Potrebne su daljnje analize da bi se utvrdila optimalna linija javnog gradskog prijevoza i njen vozni red.




Slika 55. Broj putovanja nakon uvođenja linija javnog prijevoza za jutarnji vršni sat radnim danom


5.2.3. Scenarij 3 – upravljanje u incidentnim situacijama

U ovom scenariju nalazi se novi most iz Scenarija 1. Stari most nalazi se u blizini male hidroelektrane Ozalj. Došlo je do incidentne situacije u sustavu elektroenergetske opskrbe i zbog opasnosti po živote i imovinu zatvara se stari most kako u slučaju eksplozije male hidroelektrane ne bi došlo do ljudskih žrtava, sav promet potrebno je preusmjeriti preko novog mosta. Link koji predstavlja cestu preko starog mosta prekinut je i sav promet koji se odvijao preko njega odvija se alternativnim putevima.

Koraci procedure identični su onime u Scenariju 1, jer nema nikakve promjene u samoj proceduri, već do promjene dolazi u mreži prometnica.



Slika 56. Broj putovanja u centru tijekom incidentne situacije




Slika 57. Ukupan broj putovanja u Ozlju tijekom incidentne situacije


Novim mostom se odvija se 285 putovanja, državnom cestom D228 (A) nakon zatvaranja starog mosta odvija se 447 putovanja. Ovaj scenarij koristi se samo za prikaz mogućnosti programa i nije dalje analiziran.

5.3. Raspodjela putovanja kroz dan

Raspodjela putovanja prema ulaznim i izlaznim zonama određena je prema brojanju prometa na Zagrebačkoj aveniji u Zagrebu. Moguće je pretpostaviti da je raspodjela putovanja ista, iako kategorije prometnica u Ozlju i na prometnici na kojoj je brojani promet nisu iste, jer su jedini dostupni podaci o cjelodnevnom brojanju dostupni za Zagrebačku aveniju. Udio putovanja po satima u danu prikazan je po ulaznim zonama (slika 58.) i izlaznim zonama (slika 59.). Kako bi se preciznije utvrdio broj putovanja potrebno je istraživanjem odrediti faktore produkcije i atrakcije putovanja pojedinih zona. Dnevna raspodjela putovanja radnim danom prikazana je u prilogu 1.



Slika 58. Raspodjela putovanja u ulaznim zonama radnim danom



Slika 59. Raspodjela putovanja u izlaznim zonama radnim danom

6. IZRAČUN EMISIJA IZ CESTOVNOG PROMETA U PROGRAMU COPERT: STREET LEVEL

Izračun emisija štetnih tvari i stakleničkih plinova iz cestovnog prometa provodi se na temelju poznatog broja vozila, brzine vozila i strukture voznog parka. U razmatranje se uzima sadašnje stanje i razmatraju se dva moguća scenarija. Scenariji su odabrani zbog trenutnih trendova uvođenja ekoloških zona (zabrana ulaska vozilima nižih emisijskih razreda u neka područja), elektrifikacije (zamjena vozila nižih emisijskih razreda, hibridnim i električnim vozilima) i pomlađivanja voznog parka.

6.1. O emisijama iz cestovnog prometa

Prema izvješću Europske agencije za zaštitu okoliša (engl. *European Environment Agency*), oko trećina ukupnih emisija CO₂ dolazi iz prometa. [19] Onečišćenje zraka predstavlja sve veći problem za zdravlje ljudi i okoliš, a jedan od glavnih onečišćivača je promet. Štetne tvari koje nastaju tijekom izgaranja uzrokuju bolesti respiratornog, kardiovaskularnog i neurološkog sustava. [20]

Osnovni produkti izgaranja koji nastaju u motorima s unutarnjim izgaranjem mogu se podijeliti na one koji su štetni i one koji nisu štetni za ljudsko zdravlje. Ugljikov dioksid (CO₂), kisik, dušik i vodena para nisu štetni za ljudsko zdravlje. Štetni za ljudsko zdravlje su ugljikov monoksid (CO), neizgorjeli ugljikovodici (HC), dušikovi oksidi (NO_x) i krute čestice (PM).

Ugljikov monoksid (CO) je plin bez boje i mirisa koji nastaje nepotpunim izgaranjem goriva na bazi ugljika. Opasan je jer udisanje može dovesti do trovanja. Hemoglobin koji se nalazi u crvenim krvnim stanicama na sebe puno brže veže ugljikov monoksid nego kisik, čime se sprječava opskrba stanica kisikom. Prvi simptomi trovanja primjećuju se kada je koncentracija ugljikovog monoksida u zraku iznad 70 ppm (engl. *parts per milion*).

Dušikovi oksidi (NO_x) dijele se na dušikov monoksid (NO) i dušikov dioksid (NO₂). Dušikov monoksid oksidacijom u atmosferi prelazi u dušikov dioksid koji kemijskim reakcijama dovodi do stvaranja kiselih kiša. Osim nepovoljnog utjecaja na okoliš, dušikovi oksidi imaju i negativan utjecaj na zdravlje ljudi. Uzrokuju nadraženost očiju i dušnih putova, umor i mučninu. Kod dugotrajne izloženosti postoji opasnost od pojave astme i trajnog oštećenja respiratornog i neurološkog sustava, a kao i ugljikov monoksid onemogućuje normalan prijenos kisika putem krvi. [21]

Krute čestice (PM) najvećim se dijelom sastoje od čađe, a prema srednjem promjeru dijele se na PM10 i PM2,5. PM10 su čestice čiji je srednji promjer manji od 10 μm (mikrona), a PM2,5 imaju srednji promjer manji od 2,5 μm . Takve fine krute čestice posebno su opasne za ljudsko zdravlje jer lako prodiru u respiratorni i kardiovaskularni sustav. [22] Dokazano je da čestice povećavaju smrtnost zbog kroničnih bolesti respiratornog sustava i bolesti kardiovaskularnog sustava. [23]



Neizgorjeli ugljikovodici (HC) nastaju prilikom nepotpunog izgaranja, a posebno je opasan benzen (C_6H_6). Benzen je na sobnoj temperaturi i atmosferskom tlaku bezbojna lako hlapljiva tekućina specifičnog mirisa čije su pare toksične. Kod trovanja benzenom javlja se glavobolja, zamagljen vid, poremećaji rada srca i bubrega, oštećenja jetre i dr. [24]

Ugljikov dioksid (CO_2) je staklenički plin koji izravno ne utječe na zdravlje ljudi, ali, nepovoljno utječe na efekt staklenika. Povećanje takvih plinova u atmosferi dovodi do promjena temperature, količine oborina i drugih klimatoloških elemenata. [25]

6.2. Izračun emisija iz cestovnog prometa


EMISIA SA je tvrtka specijalizirana u području prikupljanja i obrade podataka iz područja emisija tvari iz motora s unutarnjim izgaranjem. Osoblje se sastoji od inženjera strojarstva, elektrotehnike, kemije i programera s visokom znanjem iz područja zaštite okoliša. Specijalizirani su za prometnu statistiku i emisije iz područja prometa (cestovni, željeznički i avionski promet). Uz to pružaju i usluge procjene emisija tvari na lokalnoj, nacionalnoj ili globalnoj razini. [26]

Izračun emisija tvari izvodi se pomoću računalnog programa *COPERT: Street Level*, tvrtke EMISIA. Računalni program *COPERT: Street Level* predstavlja novi pristup procjeni emisija štetnih tvari iz sektora prometa. Moguće je procijeniti emisije štetnih tvari za jednu ulicu ili cijelu cestovnu mrežu i omogućava prikaz rezultata na GIS karti. [27]




Slika 60. Logo i ikona programa *COPERT: Street Levela* [27]

Program *COPERT: Street Level* izračunava emisije štetnih tvari i stakleničkih plinova pomoću emisijskih faktora. Emisijski faktori određeni su iz brojnih mjerenja emisija vozila i izraženi su u g/km, a funkcija su brzine, pogonskog goriva i *Euro* emisijskog razreda. Emisijski faktori za osobna vozila pogonjena benzinom i dizelskim gorivom prikazani su na slikama 61. i 62.



Slika 61. Emisijski faktori za osobna vozila pogonjena benzinom



Slika 62. Emisijski faktori za osobna vozila pogonjena dizelskim gorivom

Primjer 6.

Izračun emisije CO₂ istom postupkom koji provodi program *COPERT: Street Level*.

Na prometnici duljine 1,45 km kreću se sljedeća vozila:

- 10 osobnih automobila pogonjenih benzinom, brzinom 110 km/h, *Euro 3* emisijskog razreda;
- 27 osobnih automobila pogonjenih dizelskim gorivom, brzinom 80 km/h, *Euro 2* emisijskog razreda;
- 19 osobnih automobila pogonjenih benzinom, brzinom 56 km/h, *Euro 6* emisijskog razreda;
- 3 teška teretna vozila, pogonjena dizelskim gorivom, brzinom 50 km/h, *Euro 4* emisijskog razreda;
- 6 autobusa pogonjenih dizelskom gorivom, brzinom 62 km/h, *Euro 5* emisijskog razreda.

Tablica 14. Ulazni podaci za primjer 6.

Vrsta vozila	Broj vozila	Pogonsko gorivo	Brzina, km/h	Emisijski razred	Emisijski faktor CO ₂ , g/km
Osobni automobil (1), M1	10	Benzin	110	<i>Euro 3</i>	148
Osobni automobil (2), M1	27	Dizelsko gorivo	80	<i>Euro 2</i>	163
Osobni automobil (3), M1	19	Benzin	56	<i>Euro 6</i>	158
Teško teretno vozilo (4), N3	3	Dizelsko gorivo	50	<i>Euro 4</i>	652
Autobus (5), M3	6	Dizelsko gorivo	62	<i>Euro 5</i>	629

Ukupna emisija CO₂ na prometnici iznosi:

$$EM_{CO_2} = \sum_{i=1}^n EF_{CO_2_i}(v) \cdot s_i = \sum_k^{\text{gorivo}} \sum_j^{\text{kat.}} \sum_{i=1}^n EF_{CO_2_i}(v) \cdot s_i \quad (42)$$

$$EM_{CO_2} = 1,45 \cdot (10 \cdot 148 + 27 \cdot 163 + 19 \cdot 158 + 3 \cdot 652 + 6 \cdot 629)$$

$$EM_{CO_2} = 21189 \text{ g}$$

Program *COPERT: Street Level* provodi identičan postupak kao u primjeru 6, uz različite ulazne parametre u puno kraćem vremenu.

6.3. Primjer izračuna emisija u programu *COPERT: Street Level*

Kao primjer izračuna emisija u programu *COPERT: Street Level* izračunate su emisije tvari iz cestovnog prometa za Slavonsku aveniju na potezu od Kruga do Ulice Hrvatske Bratske zajednice u smjeru istok – zapad u gradu Zagrebu. *Link ID* 1 označava lijevi prometni trak, a *Link ID* 2 desni prometni trak. Postupak izračuna emisije tvari za grad Ozalj identičan je samo se u razmatranje uzima mreža prometnica.

1. Potrebno je izraditi *Excel* datoteku u koju se spremaju ulazni podaci na temelju kojih će se računati emisije. Ulazni podaci su *Link ID* (identifikacijski broj prometnice za koju će se računati emisije), koordinate početne i krajnje točke prometnice za koju se računa (*Start Lon*, *Start Lat*, *End Lon*, *End Lat*), prosječna brzina kojom se kreće prometni tok u km/h (*Speed*), dužina promatranog segmenta u kilometrima (*Lenght*), i broj vozila koja prometuju (*Volume*).

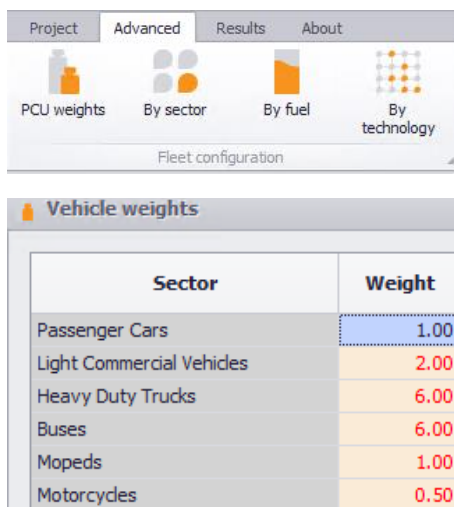
B	C	D	E	F	G	H	I
Link ID (2)	Start Lon (3)	Start Lat (4)	End Lon (5)	End Lat (6)	Speed, km/h (7)	Lenght, km (8)	Volume, n (9)
1	15,9905	45,7954	15,9693	45,7944	75	1,65	1147
2	15,9905	45,7954	15,6939	45,7944	70	1,65	912

Slika 63. *Excel* datoteka s ulaznim podacima

2. Nakon otvaranja programa i odabiranja izrade novog projekta, popunjavaju se ulazni podaci sukladno ulaznoj *Excel* datoteci kao što je prikazano na slici 64.

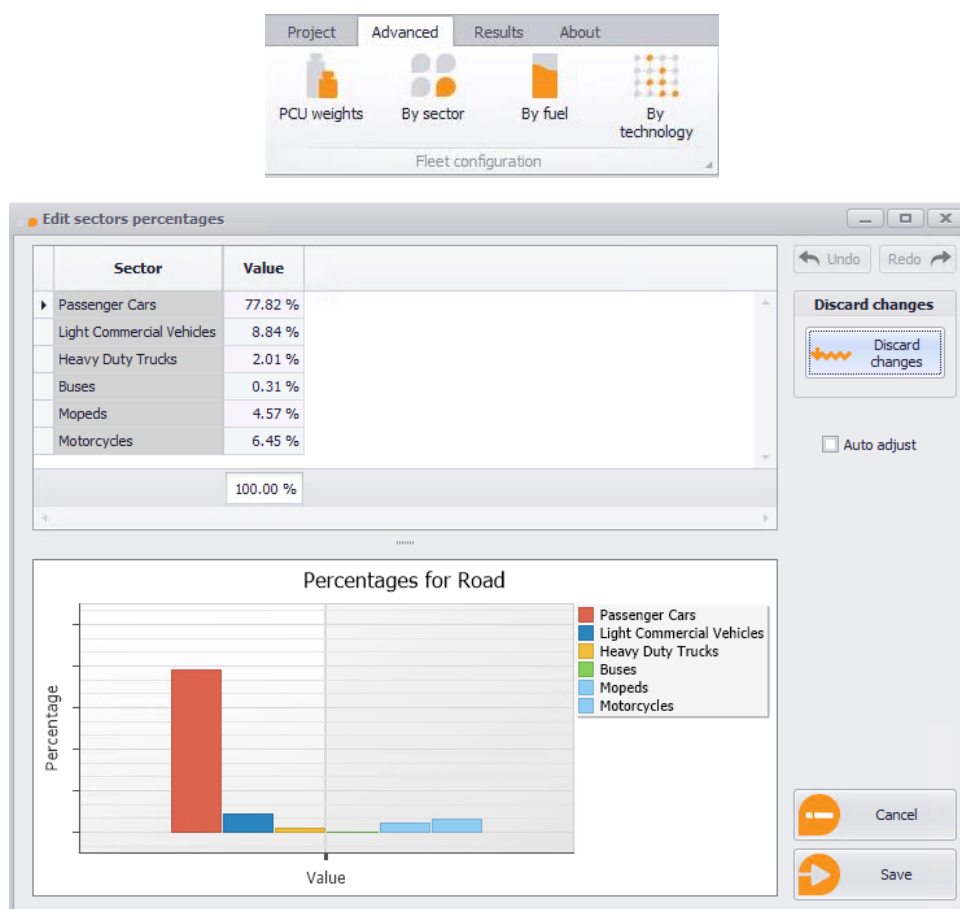
Slika 64. Dijaloški okvir za popunjavanje ulaznih podataka u *COPERT: Street Level*

3. U izborniku *Advanced* → *PCU weights* unose se predložene PCU vrijednosti definirane u poglavlju 4.2. *Passenger Car Units*.



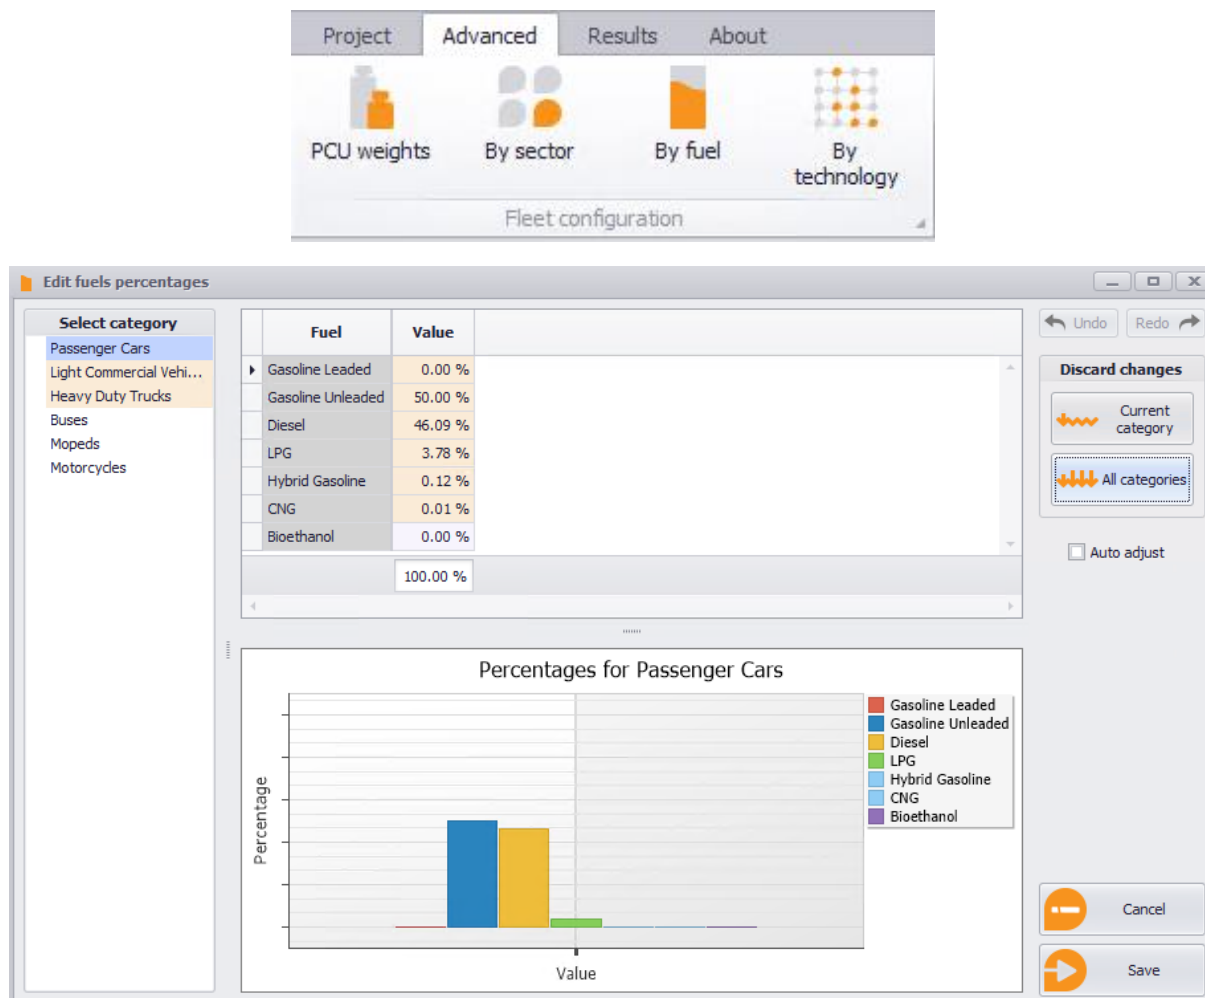
Slika 65. Predložene PCU vrijednosti

4. U izborniku *Advanced* → *By sector* unose se podaci o strukturi voznog parka na promatranim prometnicama po vrstama vozila, a za pokazni primjer koristiti se ponuđena (*default*) struktura voznog parka.



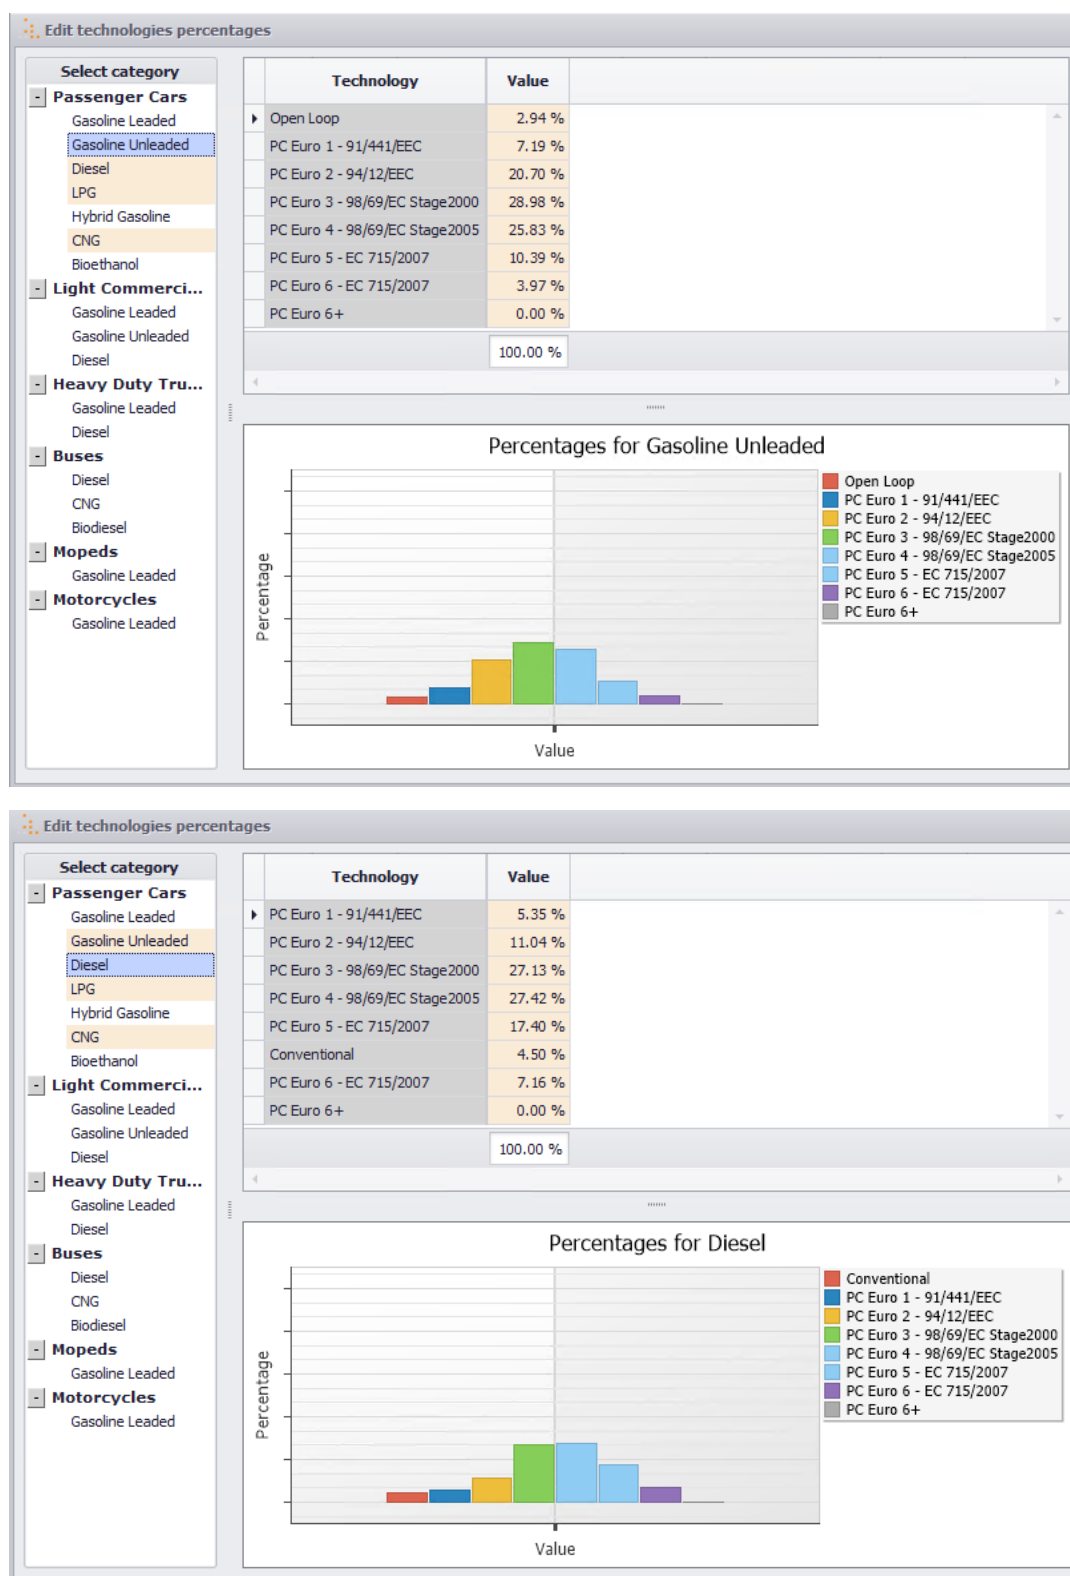
Slika 66. Ponuđena (*default*) struktura voznog parka

5. U izborniku *Advanced* → *By fuel* unose se podaci o udjelu vozila po vrsti goriva, za grad Zagreb, koji su dobiveni od Centra za vozila Hrvatske. Pretpostavlja se da su sva laka i teška teretna vozila i autobusi pogonjeni dizelskim gorivom. Svi motocikli pogonjeni su benzinom.




Slika 67. Struktura osobnih vozila prema pogonskom gorivu

6. U izborniku *Advanced* → *By technology* unose se podaci o udjelu vozila po emisijskim razredima (*Euro* normama) sukladno prikazanim u poglavlju 4.3. Struktura vozila prema *Euro* emisijskim razredima.




Slika 68. Struktura vozila pogonjenih benzinom i dizelskim gorivom prema Euro emisijskim razredima

7. Nakon unošenja svih parametara, u izborniku *Results* odabire se *Calculate* (donji desni kut, slika 69.) kako bi program izračunao emisije.



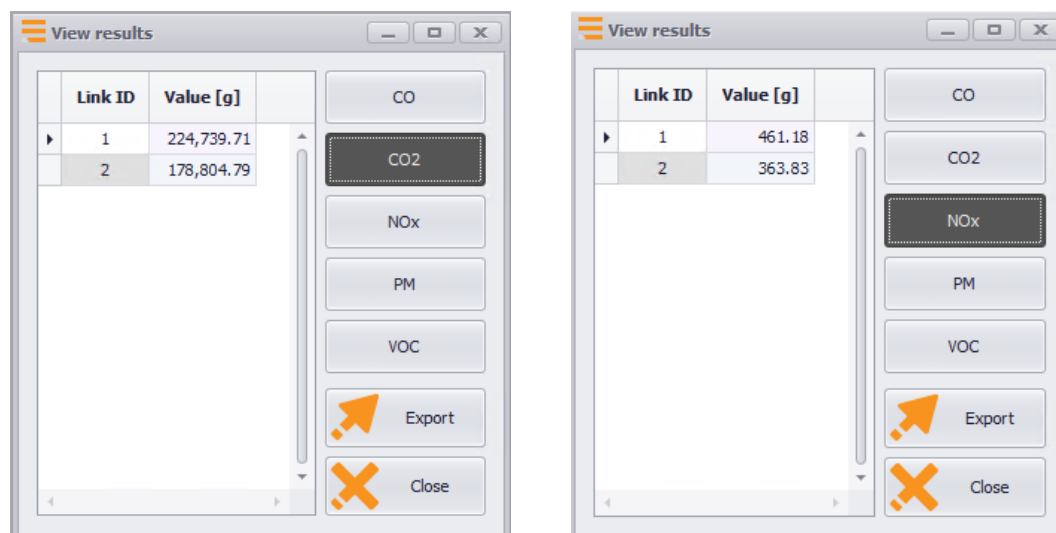
Slika 69. Pokretanje izračuna

8. U istom izborniku postoje dvije mogućnosti prikaza rezultata, *By row* i *On map*.



Slika 70. Izbornih Results

Prikaz rezultata *By row* daje rezultate za svaki *Link ID* (prometnicu) po odabranom polutantu.



Slika 71. Prikaz rezultata By Row

Prikaz rezultata *On map* koristi GPS koordinate prometnica u ulaznoj *Excel* datoteci kako bi prikazao emisije odabrane tvari na karti.



Slika 72. Prikaz rezultata *On Map* za CO_2 i NO_x

6.4. Scenariji izračuna emisija iz cestovnog prometa

Razmotreni su različiti scenariji i za njih izračunate emisije tvari iz cestovnog prometa. Bitno je naglasiti da se za ulaznu brzinu uzima brzina slobodnog prometnog toka na pojedinoj prometnici (tablica 1). U strukturi voznog parka su 100 % osobni automobili jer program *PTV Visum* na mrežu dodjeljuje broj putovanja odnosno broj osoba koje putuju mrežom. Kako bi se odredio broj automobila na mreži potrebno je podijeliti broj putovanja s prosječnom zauzetošću automobila koja prema istraživanju Hrvatskog autokluba za Republiku Hrvatsku iznosi 1,4 osobe po automobilu, kao što je prikazano na slici 73. [28].

$$\begin{array}{ccccc} \text{Broj putovanja na} & / & \text{Prosječna zauzetost} & = & \text{Broj vozila na prometnici} \\ \text{mreži} & & \text{vozila} & & \\ \\ \begin{array}{c} \text{👤 👤 👤 👤 👤 👤 👤 👤} \\ \text{👤 👤 👤 👤 👤 👤 👤 👤} \end{array} & / & \begin{array}{|c|} \hline \text{RH 2017.} \\ \hline 1,4 \\ \hline \end{array} & = & \begin{array}{c} \text{🚗 🚗 🚗} \end{array} \end{array}$$

Slika 73. Izračun broja vozila na prometnici

Razmatraju se tri scenarija odvijanja prometa. Prva znamenka kod naziva scenarija predstavlja scenarij razvoja prometa, a znamenka nakon točke predstavlja scenarij za izračun emisija.

Scenariji razvoja prometa su sljedeći:

- Case (0.X) – sadašnje stanje odvijanja prometa;
- Scenarij 1 (1.X) – gradnja novog mosta;
- Scenarij 2 (2.X) – uvođenje linije javnog gradskog prijevoza,

Za svaki od prije navedenih scenarija razvoja prometa razmatraju se sljedeći scenariji strukture voznog parka:

- Case 0 (X.0) – sadašnje stanje voznog parka;
- Scenarij 1 (X.1) – zabrana vozila nižih emisijskih razreda i zamjena novih vozilima viših emisijskih razreda;
- Scenarij 2 (X.2) – elektrifikacija, pretpostavka da je 30 % vozila električno.

Kako bi se označavanje scenarija bilo jasnije u tablici 15. prikazana je matrica scenarija sa svim kombinacijama scenarija razvoja prometa i scenarija strukture voznog parka.

Tablica 15. Matrica scenarija

		Struktura voznog parka		
		Case 0	Scenarij 1	Scenarij 2
Promet	Case 0	C 0.0	S 0.1	S 0.2
	Scenarij 1	S 1.0	S 1.1	S 1.2
	Scenarij 2	S 2.0	S 2.1	S 2.2

6.4.1. Sadašnje stanje voznog parka (X.0)

Nakon spremanja izlaznih podataka iz programa *PTV Visum* u obliku *Excel* datoteku, potrebno ih je istu datoteku unijeti u program *COPERT: Street Level* i odrediti ulazne podatke (stupce) kao što je prikazano na slici 74.

Slika 74. Izbornik za određivanje ulaznih podataka u programu *COPERT: Street Level*


Računaju se emisije za sadašnje stanje voznog parka bez ikakvih promjena u strukturi vozila (struktura voznog parka identična je onoj u poglavlju 4. Struktura voznog parka.) i trenutni model prometa bez ikakvih promjena u mreži prometnica.

6.4.2. Scenarij 1 (X.1)

Ekološki nepodobna vozila nižih emisijskih razreda (*Euro 0*, *Euro 1*, *Euro 2* i *Euro 3*) neovisno o vrsti pogonskog goriva zamjenjuje se novijim ekološki podobnim vozilima viših. Koristi se opcija *Auto adjust* da program nadomjesti stara vozila isključena iz prometa, vozilima viših emisijskih razreda. Struktura voznog parka prema *Euro* emisijskim razredima prije i nakon isključivanja ekološki nepodobnih je u tablici 16. i na slici 75.

Tablica 16. Usporedba dopuštenih emisijskih razreda za Case X.0 i Scenarij X.1


Scenarij	Vrsta goriva	Euro 0	Euro 1	Euro 2	Euro 3	Euro 4	Euro 5	Euro 6
Case X.0	Benzin	✓	✓	✓	✓	✓	✓	✓
	Dizelsko gorivo	✓	✓	✓	✓	✓	✓	✓
Scenarij X.1	Benzin	✗	✗	✗	✗	✓	✓	✓
	Dizelsko gorivo	✗	✗	✗	✗	✓	✓	✓



Slika 75. Sadašnja struktura vozila (lijevo) i struktura vozila za Scenarij 1 (desno) prema Euro emisijskim razredima

6.4.3. Scenarij 2 (X.2)

Pretpostavka je da se dio putovanja odvija unutar samog grada (odlazak liječniku, u trgovački centar itd.). Za ta putovanja pretpostavit će se korištenje električnih vozila, a njihov broj sukladno pretpostavljenom scenariju je 30 %. Mijenja se sastav vozila prema pogonskom gorivu i koristi se opcija *Auto adjust* kako bi program sam odredio udjele vozila prema pogonskom gorivu nakon unošenja promjena. Struktura vozila prema pogonskom gorivu prije i nakon elektrifikacije prikazana je na slici 76.



Slika 76. Sadašnja struktura vozila (lijevo) i struktura vozila za Scenarij 2 (desno) prema pogonskom gorivu

6.4.4. Prikaz rezultata za sve scenarije

Izračunate emisije za sve scenarije razvoja prometa i strukture voznog parka prikazane su u nastavku. Emisija CO₂ je u kilogramima, dok su emisije CO, NO_x, PM i VOC izražene u gramima. Scenarij razvoja prometa 3 u kojem se prikazuje incidenta situacija, nije uzet u razmatranje jer je samo pokazni primjer mogućnosti programa PTV VISUM.

Od promatranih scenarija najviše utjecaja na ukupno smanjenje emisija u odnosu na sadašnje stanje razvoja prometa i strukturu voznog parka ima S1.1 (izgradnja novog mosta i zamjena ekološki nepodobnih vozila). U tom slučaju emisija CO₂ smanjuje se za 42,4 %, emisija CO smanjuje se za 67,3 %, emisija NO_x smanjuje se za 41,5 %, emisija PM smanjuje se za 57,6 %, a emisija VOC smanjuje se za 72,3 %.

Tablica 17. Emisija CO₂, kg

		Struktura voznog parka		
		C 0	S 1	S 2
Promet	C 0	394	400	343
	S 1	273	227	239
	S 2	393	397	342

		Struktura voznog parka		
		C 0	S 1	S 2
Promet	C 0	100 %	+1,5 %	-12,9 %
	S 1	-30,6 %	-42,4 %	-39,3 %
	S 2	-0,2 %	+0,8 %	-13,2 %

Tablica 18. Emisija CO, g

		Struktura voznog parka		
		C 0	S 1	S 2
Promet	C 0	565	267	420
	S 1	392	185	291
	S 2	564	265	419

		Struktura voznog parka		
		C 0	S 1	S 2
Promet	C 0	100 %	-52,7 %	-25,7 %
	S 1	-30,6 %	-67,3 %	-48,5 %
	S 2	-0,2 %	-53,1 %	-25,8 %

Tablica 19. Emisija NO_x, g

		Struktura voznog parka		
		C 0	S 1	S 2
Promet	C 0	865	730	614
	S 1	600	506	426
	S 2	862	724	612

		Struktura voznog parka		
		C 0	S 1	S 2
Promet	C 0	100 %	-15,6 %	-29,0 %
	S 1	-29,9 %	-41,5 %	-50,8 %
	S 2	-0,2 %	-16,3 %	-29,2 %

Tablica 20. Emisija PM, g

		Struktura voznog parka		
		C 0	S 1	S 2
Promet	C 0	33	20	23
	S 1	23	14	16
	S 2	33	20	23

		Struktura voznog parka		
		C 0	S 1	S 2
Promet	C 0	100 %	-39,4 %	-30,3 %
	S 1	-30,3 %	-57,6 %	-51,5 %
	S 2	-0,2 %	-39,4 %	-30,3 %

Tablica 21. Emisija VOC, g

		Struktura voznog parka		
		C 0	S 1	S 2
Promet	C 0	65	26	46
	S 1	45	18	32
	S 2	65	26	46

		Struktura voznog parka		
		C 0	S 1	S 2
Promet	C 0	100 %	-60,0 %	-29,2 %
	S 1	-30,8 %	-72,3 %	-50,8 %
	S 2	-0,2 %	-60,0 %	-29,2 %

Kako bi se gradnja novog mosta opravdala potrebno je izračunati „uštedu“ koja je ostvarena smanjenjem emisija, odnosno novac koji bi se vratio kroz opću društvenu korist nakon izgradnje mosta. U Direktivi 2009/33/EZ Europskog Parlamenta od 23. travnja. 2009. o promicanju čistih i energetski učinkovitih vozila u cestovnom prometu [29] dani su troškovi za emisija u cestovnom prijevozu koji se nalaze u tablici 22.

Tablica 22. Troškovi za emisije u cestovnom prometu

CO ₂	NO _x	PM	VOC
0,035 €/kg	0,0044 €/g	0,087 €/g	0,001 €/g

Prema [30] promet u vršnom satu čini oko 15 % ukupnog prosječnog godišnjeg dnevnog prometa (PGDP). Izračun ušteda izgradnjom novog mosta prikazan je u nastavku:

$$\begin{aligned}
 D_{\text{ust}} &= (E_{\text{CO}_2\text{C0.0}} - E_{\text{CO}_2\text{S1.1}}) \cdot \text{CO}_{2\text{€}} + (E_{\text{NO}_x\text{C0.0}} - E_{\text{NO}_x\text{S1.1}}) \cdot \text{NO}_{x\text{€}} \\
 &\quad + (E_{\text{PM}_{\text{C0.0}}} - E_{\text{PM}_{\text{S1.1}}}) \cdot \text{PM}_{\text{€}} + (E_{\text{VOC}_{\text{C0.0}}} - E_{\text{VOC}_{\text{S1.1}}}) \cdot \text{VOC}_{\text{€}} \quad (43) \\
 &= (394 - 227) \cdot 0,035 + (865 - 506) \cdot 0,0044 + (33 - 14) \\
 &\quad \cdot 0,087 + (65 - 18) \cdot 0,001 \approx 155 \text{ €}
 \end{aligned}$$


Dnevne uštede nakon izgradnje novog most iznosile bi oko 155 €, a godišnje 56800 €. Ako ukupna investicija u most i pripadajući infrastrukturu iznosi oko 1 milijun €, taj novac bi se vratio kroz društvenu korist u razdoblju od 20 – ak godina, no to nije jedina dobit koja bi se ostvarila izgradnjom mosta (npr. smanjenje ukupnih vremena putovanja).

6.4.5. Izračun emisija za radni dan

Određuju se emisije iz cestovnog prometa za radni dan u razdoblju od 00:00 do 24:00. Dnevna raspodjela putovanja u ulaznim i izlaznim zonama prikazana je na slikama 58. i 59. Određen je broj za svaki sat u danu i prema tome su određene ukupne dnevne emisije putovanja prikazane u tablici 23. Emisija CO₂ kroz dan po satima prikazana je na slici 77.

Tablica 23. Dnevne emisije radnim danom

CO ₂ , kg	CO, kg	NO _x , kg	PM, kg	VOC, kg
6248,54	8,96	13,72	0,52	1,03

Slika 77. Emisija CO₂ radnim danom

7. PRIKAZ EMISIJA NA KARTI U PROGRAMU QGIS

Zbog problema s prikazom u *COPERT: Street Levelu* (nedosljednost legende po bojama, uvijek je jedna prometnica crvena [26]) za prikaz emisija na karti koristit će se program *QGIS*. *QGIS* (ranije poznat i kao *Quantum GIS*) je računalna GIS (engl. *Geographic Information System*) aplikacija otvorenog koda koja omogućuje vizualizaciju, upravljanje, uređivanje i analiziranje georeferenciranih podataka. Slično ostalim GIS programima (npr. *ArcGIS* (ESRI) ili *AUTOCAD MAP 3D* (AUTODESK)), korisnicima se omogućava stvaranje karata s većim brojem slojeva i za različite namjene. [31]




Slika 78. Logo i ikona programa QGIS [31]

7.1. Izrada karte u QGIS – u

Koraci izrade karte su:

1. Postavljanje podloge (*layer*) u kojoj se želi raditi. U ovom slučaju to će biti *layer* naziva *OpenStreetMap*. Moguće je i učitavanje željenog layera za podlogu npr. *Google maps* (slika 79.) ili reljef terena (slika 80.).




Slika 79. Podloga učitana iz Google Mapsa



Slika 80. Podloga koja se koristi za izradu karte (OpenStreetMap)

2. U izborniku se odabire opcija *New Shapefile Layer* nakon čega se otvara izbornik.



Slika 81. Ikona *New Shapefile Layer*

U njemu je potrebno odabrati vrstu geometrije (engl. *Geometry type*) novog sloja (layera) što može biti *point* (točka), *line* (linija) ili *polygon* (poligon). Nakon odabira vrste layera (slika 82.) potrebno je dodati polja koja ga opisuju (*New field*). U ovom slučaju to su Naziv prometnice (tip polja *string*, odnosno znakovi) i emisija CO₂ na prometnici (tip polja *integer*, odnosno cijeli broj).


 A screenshot of the 'New Shapefile Layer' dialog box. The 'File name' field contains 'Prometnice'. 'File encoding' is set to 'System'. 'Geometry type' is set to 'Line'. The coordinate system is set to 'EPSG:3857 - WGS 84 / Pseudo Mercator', which is highlighted with a red rectangle. Under 'New field', the 'Name' field is empty, 'Type' is '123 Whole number', 'Length' is '10', and 'Precision' is empty. There is an 'Add to fields list' button. The 'Fields list' section contains a table with two entries: 'Ime prom' (String, 80) and 'Em CO2' (Integer, 10). There is a 'Remove field' button at the bottom right. At the very bottom are 'OK', 'Cancel', and 'Help' buttons.

Name	Type	Length	Precision
Ime prom	String	80	
Em CO2	Integer	10	

Slika 82. Popunjeni izbornik *New Shapefile Layer*

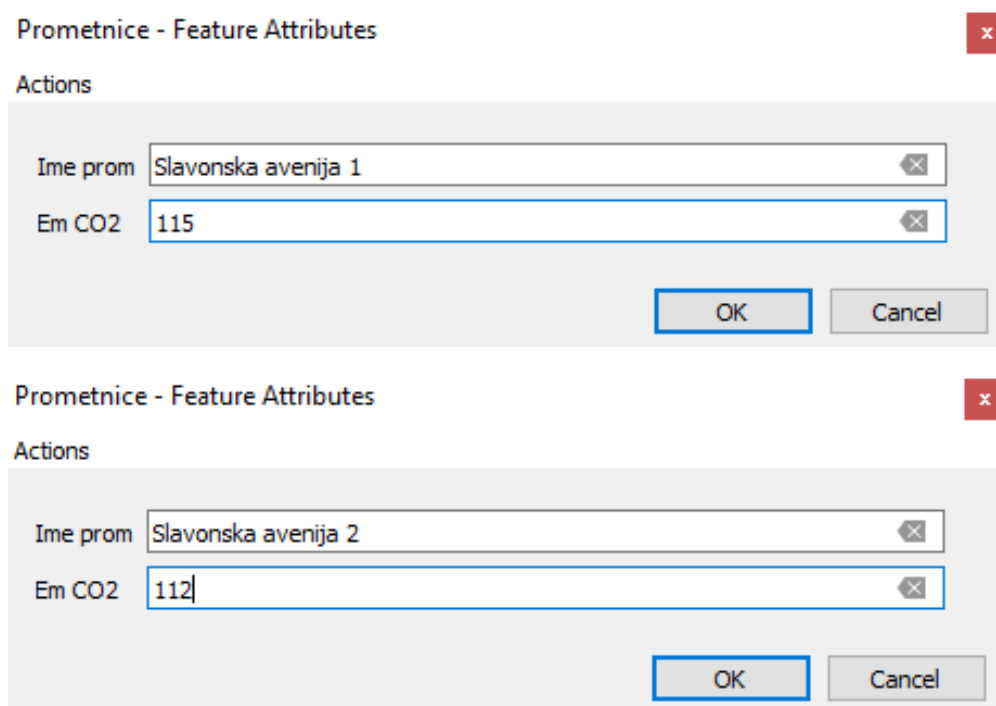
Za prikaz se koristi standardni WGS 84 (engl. *World Geodetic System*) / Pseudo Mercator koordinatni sustav koji je do 2010. godine bio referentni elipsoid za GPS satellite, a danas se koristi GRS80 (engl. *Geodetic Reference System*).

3. Nakon kreiranja layera Prometnice, odabire se *Toggle Editing*, a nakon toga *Add Line Feature* kako bi se mogla nacrtati linija na karti.



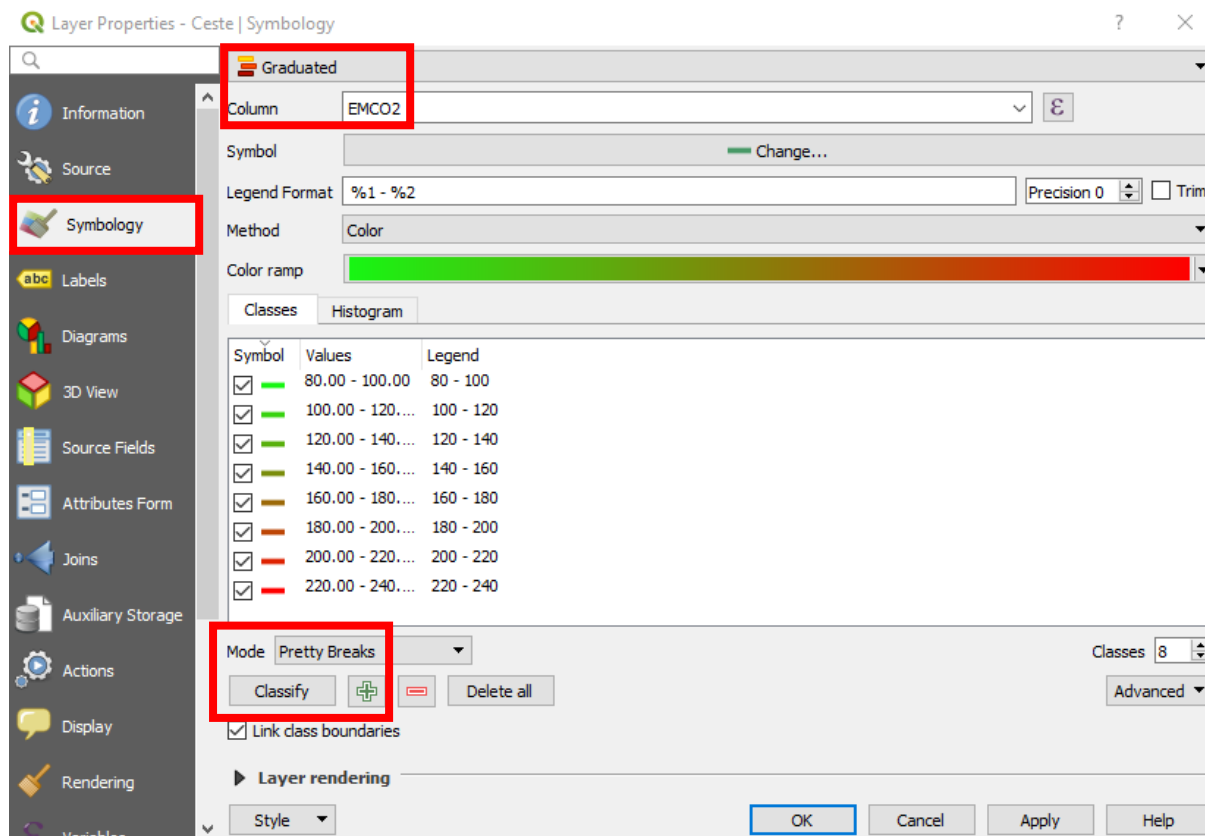
Slika 83: Postupak za crtanje linije na karti

Nakon crtanja linije i potvrđivanja njezina izgleda lijevim klikom miša otvara se dijaloški okvir *Feature Attributes* u koji je potrebno unijeti attribute linije, u ovom slučaju ime prometnice i emisiju CO₂. Pod nazivom Slavonska avenija 1 je lijevi prometni trak u smjeru istok – zapad, a pod nazivom Slavonska avenija 2 je desni prometni trak u smjeru istok – zapad



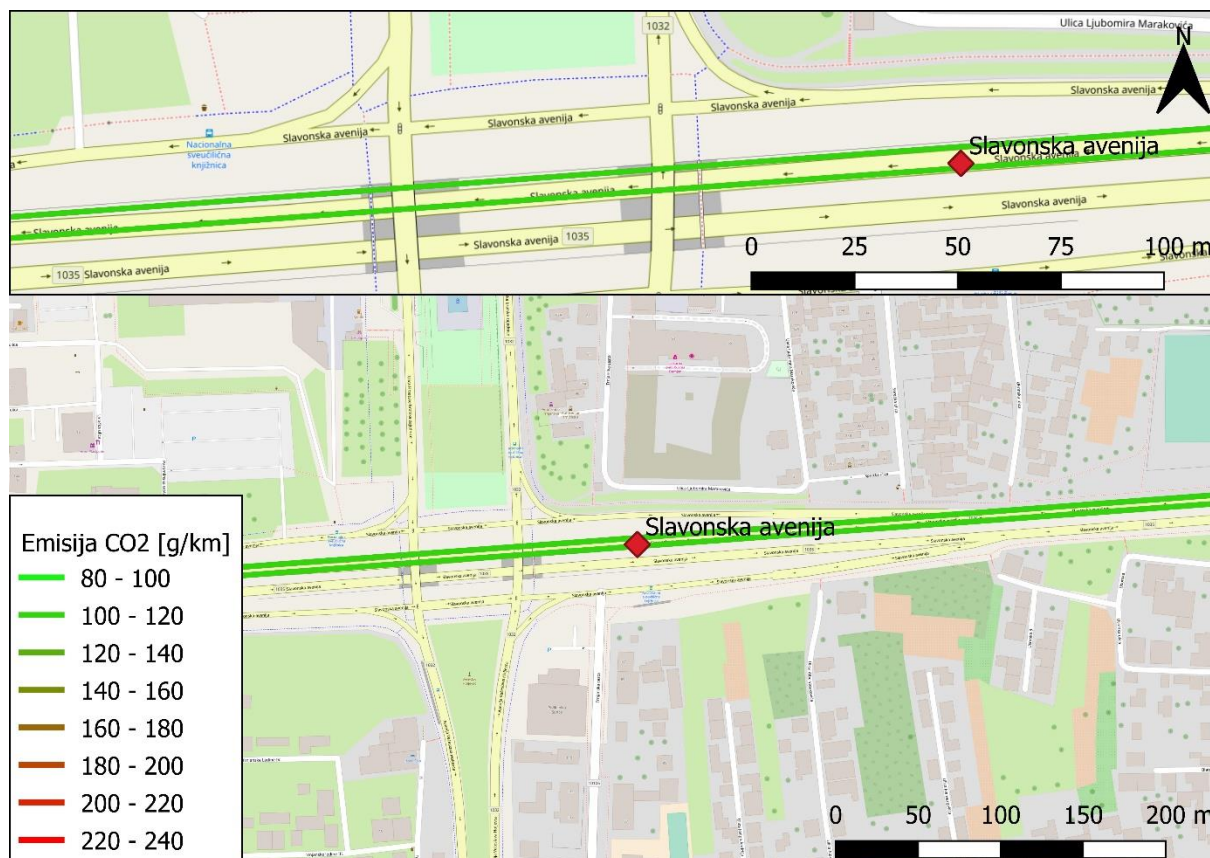
Slika 84. Atributi prometnica

4. Nakon otvaranja dijaloškog okvira *Layer Properties* (slika 85.) za layer Prometnice, odabire se *Symbology*, u padajućem izborniku odabire se *Graduated*, u padajućem izborniku *Column* odabire se polje (*Field*) za koje se želi provesti klasifikacija, u ovom slučaju to je EMCO2. U padajućem izborniku *Mode*, odabire se *Pretty Brakes*. Nakon svega odabire se *Classify* kako bi program rasporedio linije po bojama i vrijednostima.



Slika 85. Dijaloški okvir *Layer Properties*

5. Nakon što su prometnice „pobojene“ prema emisijama odabire se *Project* → *New Print Layout*. Odabire se format papira na kojem se želi iscrtati karta i dodaju svi atributi koje se želi na karti poput strelice koja označava sjever, legende, mjerila, „karte u karti“ kako bi se detalji jasnije vidjeli. Karta izrađena po prethodnim koracima nalazi se na slici 86.



Slika 86. Emisija CO₂ za odabrani primjer u QGIS - u

Emisija CO₂ na prometnicama u Ozlju prikazana je na slici 87. Državna cesta D228 je cijela pobojena u maslinastu boju. Broj vozila na cijeloj dionici nije isti, ali je emisijski faktor na prometnici jedan, zbog iste brzine i homogenog sastava vozila. Iz istog razloga su sve županijske ceste isto pobojene, a emisijski faktor je veći nego za državne ceste, jer je brzina vožnje manja. Nakon određivanja brzine prometnog toka za svaku prometnicu i sastava voznog parka prema kategorijama vozila, moguće je odrediti preciznije emisijske faktore za sve prometnice.



Slika 87. Emisija CO₂ po prometnicama u Ozlju

8. ZAKLJUČAK

U diplomskom radu proveden je izračun emisija iz cestovnog prometa u gradu Ozlju. Broj vozila, u ovom slučaju automobila na prometnicama procijenjen je iz ukupnog broja putovanja. Broj putovanja na prometnicama izračunat je koristeći program *PTV Visum* u kojem je napravljen simulacijski model klasičnog četverostupanjskog modela prometne potražnje za koji je teorijska podloga dana u poglavlju 3. Klasični četverostupanjski model prometne potražnje, a emisije iz vozila izračunate su u programu *COPERT: Street Level*. Prema ulaznim parametrima izrađen je makroskopski model prometnog toka jer u obzir uzima brzinu prometnih tokova i protok vozila na prometnicama.

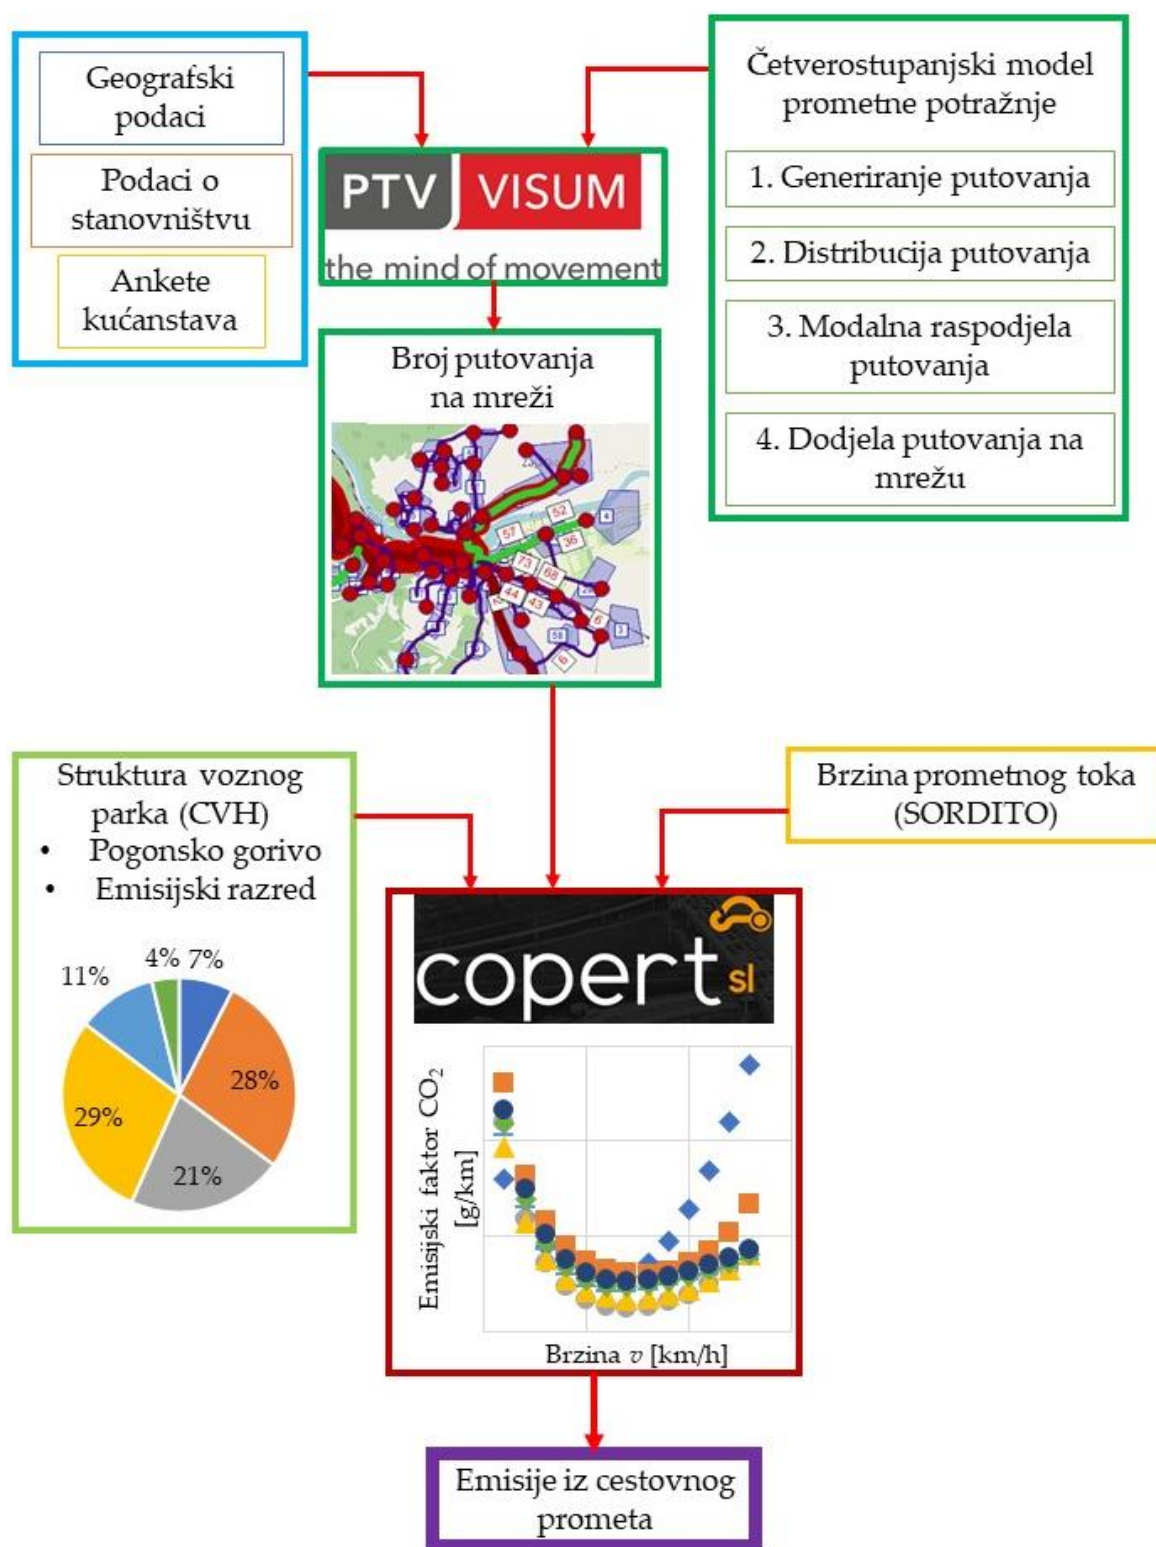
Kreiranje modela počinje na karti označavanjem raskrižja (čvorova), prometnica (linkova), zona i konektora na promatranom području. Svakom raskrižju dodjeljuju se atributi koji ga opisuju i služe za izračun njegove propusne moći. Prometnicama se dodjeljuje rang prometnice (državna cesta, županijska cesta, lokalna cesta i dr.), atributi svakog ranga prometnice unaprijed su definirani (najveća dopuštena brzina prometnog toka, kapacitet). Zone predstavljaju područja homogenih značajki (škole, stambene zone, industrijske zone), ulazne i izlazne zone. Ulazne i izlazne zone koriste se kako bi se nakon brojanja prometnih tokova u njima mogli unijeti točni podaci o ulazu i izlazu vozila i promatranog područja. U stambenim zonama potrebno je procijeniti broj kuća ili stanova. Za svaku kuću ili stan poznati su podaci produkcije i atrakcije putovanja iz [14] te se pomoću funkcija produkcije i atrakcije mogu procijeniti. Svaka zona posjeduje centorid, u kojem su smještene sve značajke zone. Konektori predstavljaju spoj centroida zone s izlaznim čvorovima (raskrižjima) iz te zone i služe za raspodjelu putovanja koje zona generira na izlazne čvorove. Nakon stvaranja potpune „karte“ potrebno je definirati korake procedure kako bi se simulacija mogla pokrenuti. Definiranje počinje dodavanjem *Initial Assignmenta*, koji briše sve podatke prethodnih simulacija kako kod promjene ulaznih podataka ne bi došlo do kolizije i pogrešnih izračuna. Nakon toga slijedi prvi korak četverostupanjskog modela prometne potražnje, odnosno procjena distribucija putovanja kojom se procjenjuje ukupan broj privučenih i generiranih putovanja u/iz zone u analiziranom području. Ukupan zbroj putovanja koja nastaju i koja su privučena u promatranom području moraju biti jednaki, što najčešće nije slučaj. S obzirom na to da su modeli za procjenu produkcije putovanja (kategorijska analiza ili regresijska analiza) kvalitetniji od modela za procjenu atrakcije putovanja, ukupan zbroj atrakcije putovanja prilagođava se ukupnom zbroju produkcije putovanja. Sljedeći korak četverostupanjskog modela je distribucija putovanja, odnosno

određivanje **OD** matrice pomoću gravitacijskog modela za predviđanje putovanja između zona promatrane prometne mreže. Potrebno je pretpostaviti generaliziranu distribucijsku funkciju putovanja, koja je u ovom slučaju Tannerova funkcija, a parametri su preuzeti iz [14]. Najvažniji korak četverostupanjskog modela je modalna raspodjela putovanja, odnosno odabir načina prijevoza kojim će se izvršiti putovanje (osobni automobil, javni gradski prijevoz, pješaćenje, bicikl i dr.) Odabir ovisi o dostupnosti moda prijevoza i svrsi putovanja. U scenariju kada postoji više modova prijevoza (osobni automobil i javni gradski prijevoz) koristi se multinomijalni Logit model. Završni korak je dodjela putovanja na mrežu odnosno spajanje prijevozne ponude i potražnje. U slučajevima kada postoji više ruta putovanja odabire se ona s najmanjim generaliziranim troškovima putovanja. Za dodjeljivanje putovanja na mrežu koristi se ekvilibrijalna metoda dodjeljivanja putovanja. Ekvilibrij (ravnoteža mreže) je postignut kada putnici ne mogu naći troškovno povoljniju rutu od one koju trenutno koriste. Bitno je naglasiti da izlazni podaci iz programa nisu broj vozila na prometnici, već broj putovanja, da bi se utvrdio broj vozila potrebno je broj putovanja podijeliti s prosječnom zauzetošću vozila.

Razmatrana su tri scenarija razvoja prometa, a svaki je odabran zbog svoje specifičnosti. Svaki od scenarija spojen je s nekoliko scenarija strukture vozila i svi scenariji su uspoređivani sa sadašnjim stanjem odvijanja prometnih tokova i strukture vozila kako bi se odabrao najpovoljniji za smanjenje emisija. Prvi scenarij razvoja prometa, je simulacija odvijanja prometnih tokova nakon gradnje novog mosta uzvodno od središta grada i sadašnjeg mosta. Tim scenarijem značajno se smanjuje vrijeme putovanja iz smjera sjeverozapada do centra grada i prema Karlovcu. Scenarij izgradnje novog mosta, u kombinaciji sa scenarijem promjene strukture vozila, u kojem se ekološki nepodobna vozila nižih emisijskih razreda, zamjenjuju ekološki podobnim vozilima viših emisijskih razreda rezultira najvećim smanjenjem emisija iz cestovnog prometa. Smanjenje CO u odnosu na sadašnje stanje je 67,3 %, smanjenje CO₂ je 42,4 %, smanjenje NO_x je 41,5 %, smanjenje PM za 57,6 %, a smanjenje VOC za 72,3 %. Procijenjena godišnja ušteda prema troškovniku emisija iznosi 50 – ak tisuća €. Potrebno je detaljno analizirati troškove izgradnje mosta i mogućnosti zamjene ekološki nepodobnih vozila, ekološki podobnim vozilima kako bi se utvrdila stvarna isplativost ovakvog scenarija.

Scenarij uvođenja linije javnog gradskog prijevoza nema utjecaja na smanjenje broja putovanja i smanjenje emisija jer je u vršnom periodu korisnost tog moda prijevoza svega 0,013. Scenarij elektrifikacije nije potpuno realan i potrebno je detaljno proučiti navike putovanja domicilnog stanovništva čija putovanja imaju i izvorište i odredište unutar promatranog područja kako bi se mogao bolje odrediti udio takvih

putovanja, a samim time i električnih vozila koja će zamijeniti vozila pogonjena fosilnim gorivima. Dijagram toka izrade modela i prometa i procjene emisija tvari iz cestovnog prometa prikazan je na slici 88.



Slika 88. Dijagram toka procjene emisija tvari iz cestovnog prometa

Prikazani model prometa i izračuna emisija tvari iz cestovnog prometa, te prikazani rezultati mogu biti temelj i motivacija za daljnje poboljšanje točnosti modela odvijanja prometa i izračuna emisija iz cestovnog prometa. Mogući pravci daljnjeg razvoja uključuju:

- Anketiranje kućanstava kojim se utvrđuju podaci o putovanjima svih članova kućanstva svim modovima prijevoza unutar područja promatranja, tako se utvrđuju točna izvorište i odredišta putovanja, odnosno odmah se kreira **OD** matrica, pa je moguće preskočiti prva tri koraka četverostupanjskog modela i odmah se može pristupiti dodjeli putovanja na mrežu;
- Snimanje prometnih tokova u ulazno – izlaznim zonama, kako bi se njihovim pregledavanjem utvrdio broj vozila koja ulaze/izlaze iz zona, prosječna zauzetost vozila i postotak teških vozila (engl. PHV – *percentage of heavy vehicles*), utvrđivanjem postotka teških vozila poboljšalo bi točnost modela prometa, kao i točnost izračuna emisija iz cestovnog prometa, jer se trenutno provodi izračun samo za osobne automobile, koji imaju manje emisijske faktore od teških vozila;
- Snimanje prometnih tokova na strateški bitnim točkama utvrđenim nakon analize kako bi se utvrdila modalna raspodjela putovanja (npr. snimanje prometnih tokova na mostu kako bi se utvrdio broj putovanja osobnim automobilima, biciklima i pješačkih putovanja);
- Određivanje prosječne brzine prometnih tokova, kako bi izračun emisija bio točniji odnosno integracija modela s aplikacijom *SORDITO* u kojoj su na karti prikazane brzine prometnog toka na mreži prometnica s intervalom od 5 minuta, odnosno moguće je odraditi 12 izračuna za sat odnosno 288 izračuna za dan;
- Konačni cilj je izrada modela za 24 sata, 7 dana u tjednu, odnosno za svaki dan i sat u tjednu i taj postupak automatizirati.

LITERATURA

- [1] Novačko, L.; „Prometno modeliranje u cestovnom prometu“; Fakultet prometnih znanosti, Interna skripta, 2015.
- [2] Speranza, M. G., Oliveira, J. F.; „Traffic Flow Modeling: Introduction to Traffic Flow Theory Through a Genealogy of Models“, Springer, 2018.
- [3] Bristow, A.; „Traffic Modelling Guidelines“, Transport for London, 2010.
- [4] Wonderopolis, „Where the Wonders of Learning Never Cease“, web stranica: <https://wonderopolis.org/>, zadnje pristupljeno: rujan 2018.
- [5] Savaresi, S. M.; „Semi – Active Suspension Control Desing for Vehicles“, Butterworth – Heinmann, 2010.
- [6] Horvat, D.; „Survey of Adcanced Suspension Developments and Related Optimal Control Applications“, Automatica, 1997; 33 (10): 1781 - 1817
- [7] Grad Zagreb, službene stranice, web stranica: <https://www.zagreb.hr/karakteristike-podrucja-obuhvacenog-studijom/1888>, zadnje pristupljeno: rujan 2018.
- [8] Šagi, G., Tomić, R., Ilinčić, P.; „Razvoj propisa o dopuštenim emisijama štetnih tvari iz motora s unutarnjim izgaranjem“, Goriva i maziva, 48, 2, 159-188, Zagreb, 2009.
- [9] Grad Ozalj, službene stranice; web stranica: <http://ozalj.hr/ozalj/o-gradu/povijest/>, zadnje pristupljeno: rujan 2018.
- [10] Leksikografski zavod „Miroslav Krleža“, O Ozlju; web stranica: <http://www.enciklopedija.hr/natuknica.aspx?id=46006>, zadnje pristupljeno: studeni 2018.
- [11] Wikipedia; web stranica: <https://hr.wikipedia.org/wiki/Ozalj>, zadnje pristupljeno: rujan 2018.
- [12] Google maps; web stranica: <https://www.google.com/maps>, zadnje pristupljeno: studeni 2018.

- [13] Jović, J., Popović, M.; „Zbirka zadataka iz planiranja saobraćaja“, Saobraćajni fakultet u Beogradu, 1998.
- [14] „Trip Generation“, Institute of Transportation Engineers, 2008.
- [15] Casey, H. J.; „Applications to traffic engineering of the law of retail gravitation,“ Traffic Quarterly, IX(1), 23-35., 1931.
- [16] Cerovac, V.; „Tehnika i sigurnost prometa“, Fakultet prometnih znanosti, Zagreb, 2001.
- [17] Wardrop, J. G.; „Some Theoretical Aspects of Road Traffic Research“, 1952.
- [18] PTV Visum; [web stranica: http://vision-traffic.ptvgroup.com/en-us/products/ptv-visum/](http://vision-traffic.ptvgroup.com/en-us/products/ptv-visum/), zadnje pristupljeno: studeni 2018.
- [19] EEA; „European Union emission inventory report 1990–2015 under the UNECE Convention on Long-range Transboundary Air Pollution (LRTAP). No 9/2017“, web stranica: <https://www.eea.europa.eu/publications/annual-eu-emissions-inventory-report>, zadnje pristupljeno: studeni 2018.
- [20] Costa, L. G., Cole, T. B., Coburn, J., Chang, Y.; „Neurotoxicity of traffic related air pollution“, NeuroToxicology. 2017 Mar;59:133-139.
- [21] Babić, V.; „Izvori i svojstva NO_x spojeva“, Završni rad, Fakultet kemijskog inženjerstva i tehnologije, 2015.
- [22] Kurt, O. K., Zhang, J., Pinkerton, K. E.; „Pulmonary health effects of air pollution“, Current Opinion in Pulmonary Medicine, 138 – 143
- [23] Poorfakhraei, A., Tayrani, M., Rowangould, G.; „Evaluating health outcomes from vehicles emissions exposure in the long range regional transportation planning process“, Journal of Transport and Health, 501 – 505
- [24] Poplašen, D., „Aromatski ugljikovodici – izloženost i utjecaj na zdravlje“, Sigurnost, 65 – 67
- [25] Ministarstvo zaštite okoliša i prirode, „Više o učinku staklenika“, web stranica: <http://klima.mzoip.hr/default.aspx?id=43>, zadnje pristupljeno: listopad 2018.
- [26] Bunjevac, M.; „Procjena emisija iz cestovnog prometa programom COPERT: Street Level“, Završni rad, Fakultet strojarstva i brodogradnje, Zagreb, 2017.


- [27] EMISIA: mission for environment, Opći podaci o programu COPERT: *Street Level*, web stranica: <http://emisia.com/products/copert-street-level>, zadnje pristupljeno: listopad 2018.
- [28] Hrvatski autoklub; web stranica: <https://www.hak.hr/sigurnost-u-prometu/projekti/10zlatnihpravila/>, zadnje pristupljeno: listopad 2018.
- [29] Direktiva 2009/33/EZ Europskog parlamenta o promicanju čistih i energetski učinkovitih vozila u cestovnom prometu, web stranica: <https://eur-lex.europa.eu/legal-content/HR/TXT/?uri=CELEX%3A32009L0033>, zadnje pristupljeno: studeni 2018.
- [30] Dadić, I., Kos, G., Ševrović, M.; „Teorija prometnog toka“, Fakultet prometnih znanosti, Zagreb, 2014.
- [31] QGIS; web stranica: <https://www.qgis.org/en/site/about/index.html>, zadnje pristupljeno: studeni 2018.
- [32] May, A. D.; „Traffic Flow Fundamentals“, Prentice – Hall, 1990.
- [33] Ni, D.; „Traffic Flow Theory“, Butterworth – Heinmann, 2015.
- [34] Pardalos, P. M.; „Transportation Systems Analysis“, Springer, 2009.
- [35] Spiegelman, C. H., Park, E. S., Rillet, L. R.; „Transportation Statistic and Microsimulation“, Chapman and Hall, 2011.
- [36] O’Flaherty; „Transport Planning and Traffic Engineering“, Butterworth – Heinmann, 2016.
- [37] Roess, R. P., Prassas, E. S., McShane, W. L.; „Traffic Engineering“, Prentice Hall, 2004.
- [38] Ortuzar, J. D., Willumensen, L. G.; „Modelling transport“, Wiley, 2011.

PRILOG

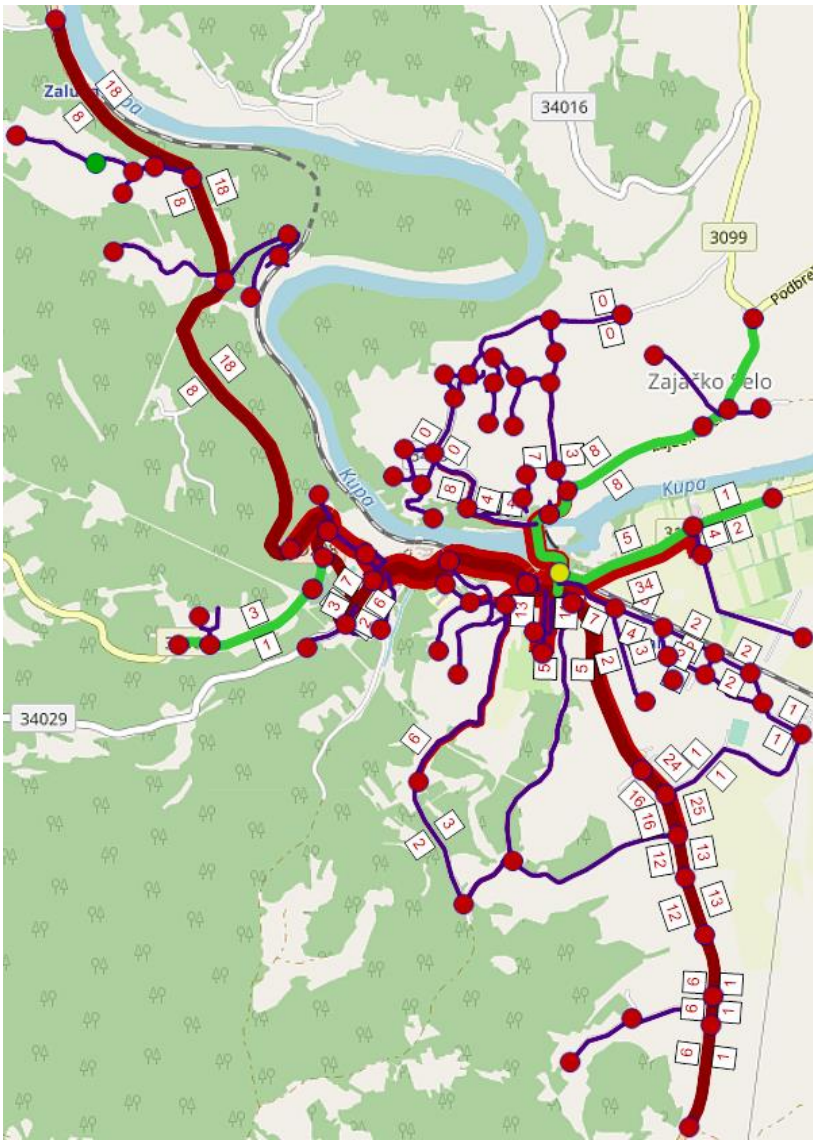
1. Dnevna raspodjela putovanja u gradu Ozlju
2. CD - R

Prilog 1. Dnevna raspodjela putovanja u gradu Ozlju (1. dio)

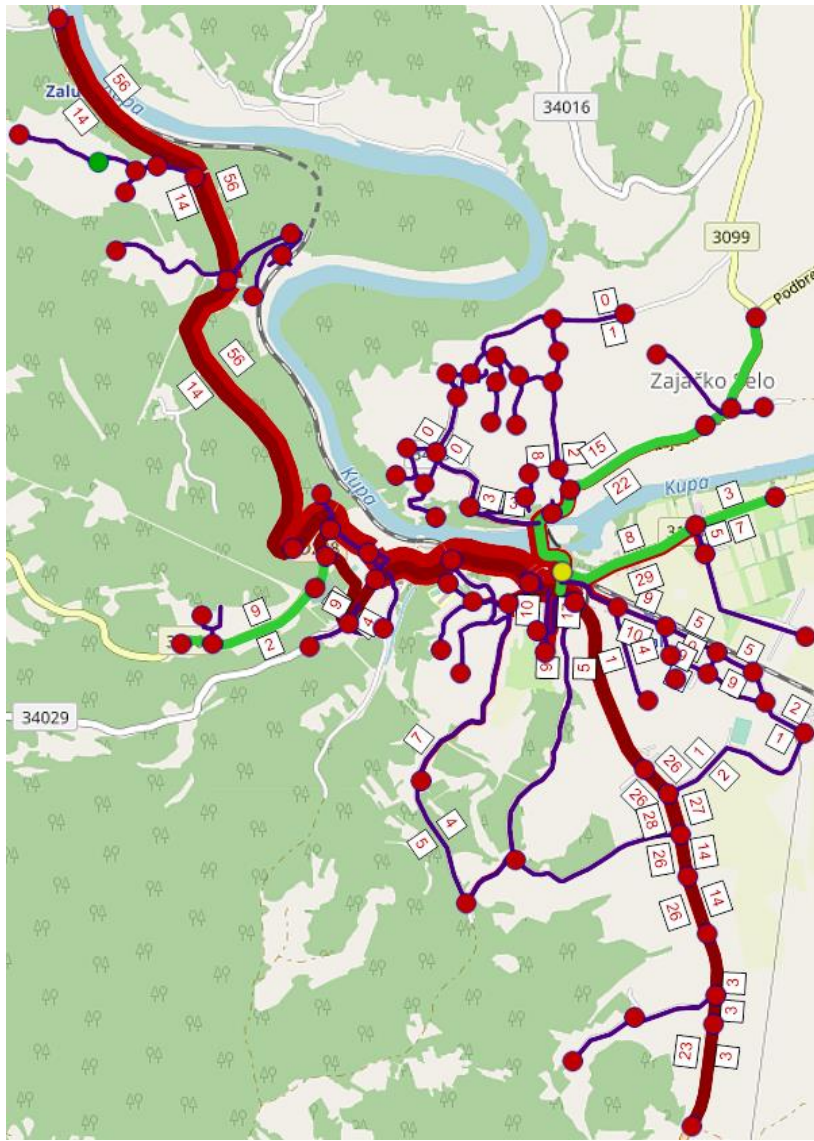
Raspodjela putovanja radnim danom
od 03:00 do 04:00




Raspodjela putovanja radnim danom
od 04:00 do 05:00




Raspodjela putovanja radnim danom
od 05:00 do 06:00



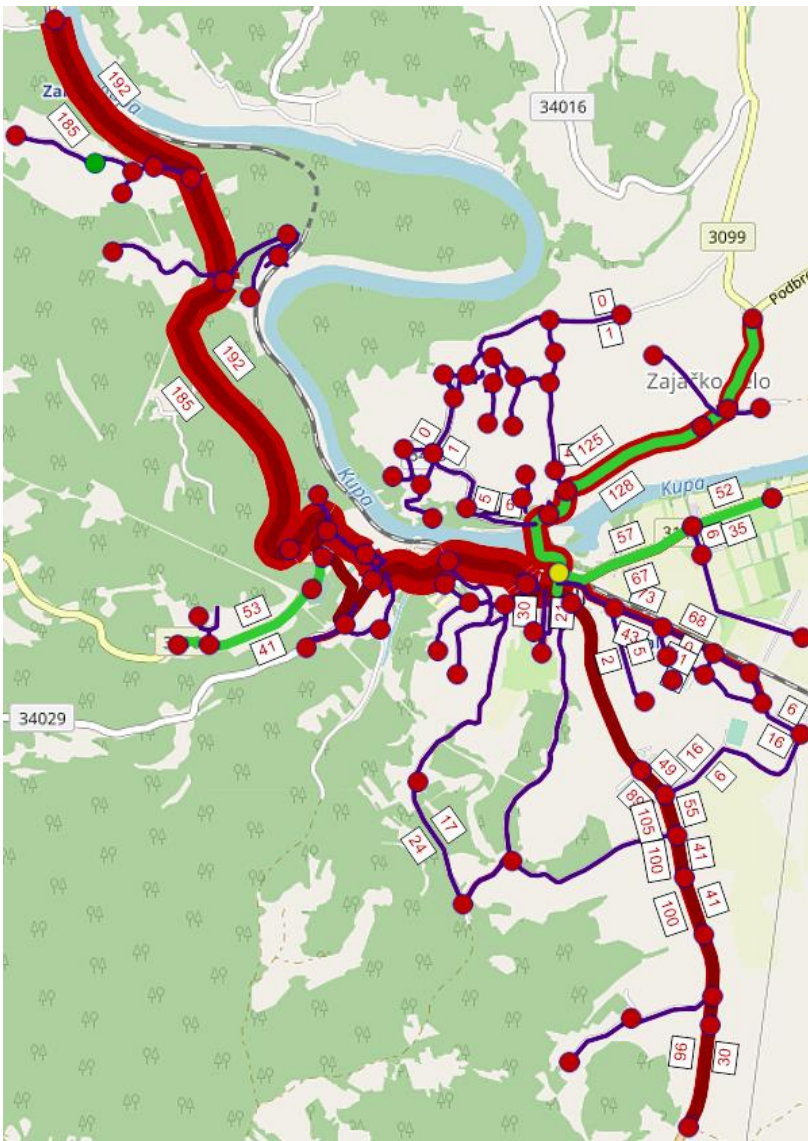
Raspodjela putovanja radnim danom
od 06:00 do 07:00




Raspodjela putovanja radnim danom
od 07:00 do 08:00



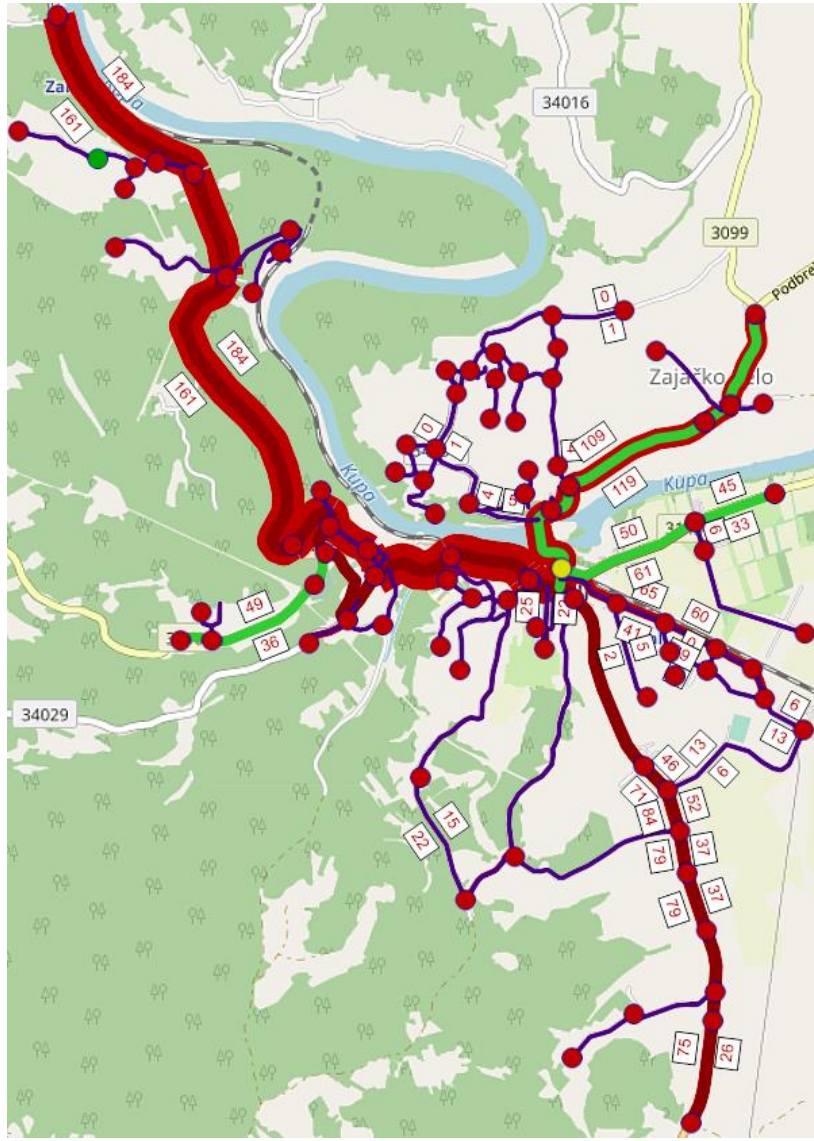
Raspodjela putovanja radnim danom
od 08:00 do 09:00




Raspodjela putovanja radnim danom
od 09:00 do 10:00




Raspodjela putovanja radnim danom
od 10:00 do 11:00



Raspodjela putovanja radnim danom
od 11:00 do 12:00




Raspodjela putovanja radnim danom
od 12:00 do 13:00




Prilog 1. Dnevna raspodjela putovanja u gradu Ozlju (2. dio)

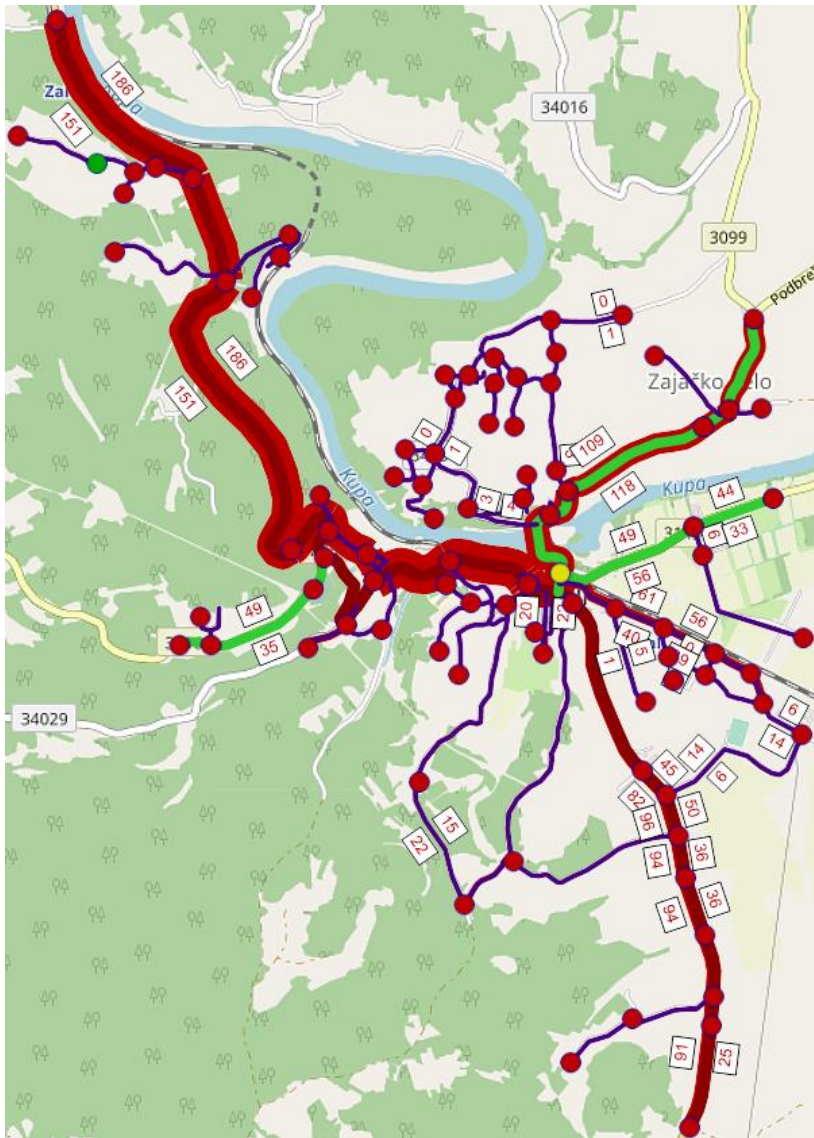
Raspodjela putovanja radnim danom
od 13:00 do 14:00




Raspodjela putovanja radnim danom
od 14:00 do 15:00




Raspodjela putovanja radnim danom
od 15:00 do 16:00




Raspodjela putovanja radnim danom
od 16:00 do 17:00




Raspodjela putovanja radnim danom
od 17:00 do 18:00




Raspodjela putovanja radnim danom
od 18:00 do 19:00




Raspodjela putovanja radnim danom
od 19:00 do 20:00



Raspodjela putovanja radnim danom
od 20:00 do 21:00



Raspodjela putovanja radnim danom
od 21:00 do 22:00



Raspodjela putovanja radnim danom
od 22:00 do 23:00

